



TUGAS AKHIR - SF 141501

**INVERSI DATA MAGNETOTELLURIK 1-D BERBASIS RR-PSO
DENGAN METODE SELEKSI *APPROXIMATE NON-
DOMINATED SORTING* (ANS)**

**Haiyina Hasbia Amania
NRP 1112100091**

**Dosen Pembimbing
Prof.Dr.rer.nat. Bagus Jaya Santosa, S.U.
Dr. Sungkono**

**DEPARTEMEN FISIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2017**



TUGAS AKHIR - SF 141501

**INVERSI DATA MAGNETOTELLURIK 1-D BERBASIS RR-
PSO DENGAN METODE SELEKSI *APPROXIMATE NON-
DOMINATED SORTING* (ANS)**

**Haiyina Hasbia Amania
NRP 1112100091**

**Dosen Pembimbing
Prof.Dr.rer.nat. Bagus Jaya Santosa, S.U.
Dr. Sungkono**

**DEPARTEMEN FISIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2017**



FINAL PROJECT - SF 141501

**1D MAGNETOTELLURIC DATA INVERSION USING
RR-PSO WITH APPROXIMATE NON-DOMINATED
SORTING (ANS) AS THE SELECTION METHOD**

**Haiyina Hasbia Amania
NRP 1112100091**

**Advisors
Prof.Dr.rer.nat. Bagus Jaya Santosa, S.U.
Dr. Sungkono**

**Department of Physics
Faculty of Mathematics and Science
Institut Teknologi Sepuluh Nopember
Surabaya 2017**

LEMBAR PENGESAHAN
INVERSI DATA MAGNETOTELLURIK 1-D BERBASIS
RR-PSO DENGAN METODE SELEKSI *APPROXIMATE*
***NON-DOMINATED SORTING* (ANS)**

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat Untuk Menyelesaikan

Program S-1

Pada

Bidang Studi Geofisika

Program Studi S-1 Departemen Fisika

Fakultas Matematika Dan Ilmu Pengetahuan Alam

Institut Teknologi Sepuluh Nopember

Oleh :

Haiyina Hasbia Amania

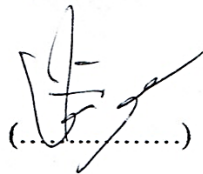
NRP. 1112 100 091

Disetujui oleh Pembimbing Tugas Akhir :

1. Prof.Dr.rer.nat. Bagus Jaya Santosa, S.U.

()

2. Dr. Sungkono

()



INVERSI DATA MAGNETOTELLURIK 1-D BERBASIS RR-PSO DENGAN METODE SELEKSI *APPROXIMATE* *NON-DOMINATED SORTING* (ANS)

Penulis : Haiyina Hasbia Amania
NRP : 1112100091
Departemen : Fisika FMIPA ITS
Dosen Pembimbing 1 : Prof.Dr.rer.nat. Bagus Jaya Santosa,
S.U.
Dosen Pembimbing 2 : Dr. Sungkono

Abstrak

Optimasi multiobjektif berfungsi untuk mengestimasi parameter model dengan fungsi tujuan lebih dari satu, sebagaimana dalam proses inversi data magnetotellurik (MT). Banyaknya fungsi objektif yang ingin dioptimasi memengaruhi kecepatan komputasi dari algoritma yang digunakan. Pada penelitian ini, dilakukan pemodelan inversi dengan menggunakan RR-PSO_ANS untuk mengestimasi parameter resistivitas dan ketebalan dari data MT 1D. Algoritma ini memiliki kecepatan pencarian solusi dan konvergensi yang cepat dan dapat memberikan informasi mengenai ketidakpastian solusi melalui *Pareto Front* (PF) yang dihasilkan. Dilakukan uji algoritma terhadap data ZDT dan dilakukan perbandingan dengan NSGA-II, didapatkan bahwa meskipun nilai IGD NSGA-II sedikit lebih kecil, RR-PSO_ANS memiliki kecepatan komputasi yang lebih cepat, yaitu 30 kali lebih cepat dibandingkan dengan NSGA-II. Selain itu, PF yang dihasilkan juga sangat dekat dengan PF yang sebenarnya. Selanjutnya, hasil inversi beberapa data sintetik dan lapangan menunjukkan bahwa algoritma RR-PSO_ANS mampu mengestimasi parameter fisis MT 1D dengan baik, dimana nilai RMS yang dihasilkan hanya berada pada orde 10^{-2} - 10^{-3} untuk data sintetik, dan kurang dari 5% untuk data lapangan.

Kata kunci: *ANS, Inversi magnetotellurik 1D, Multiobjektif, RR-PSO*

1D MAGNETOTELLURIC DATA INVERSION USING RR-PSO WITH APPROXIMATE NON-DOMINATED SORTING (ANS) AS THE SELECTION METHOD

Name : Haiyina Hasbia Amania
NRP : 1112100091
Departement : Fisika FMIPA ITS
Advisor 1 : Prof.Dr.rer.nat. Bagus Jaya Santosa,
S.U.
Advisor 2 : Dr. Sungkono

Abstract

In the multiobjective optimization, the number of objectives that should be minimized often affects the computing performance of an algorithm. Within this study, an inversion modeling is conducted by using RR-PSO_ANS to estimate the resistivity and the thickness of 1D magnetotelluric data. RR-PSO_ANS has an exceptionally fast convergence rate and rapid solution-search pace. The algorithm is tested and compared with NSGA II algorithm for solving the ZDT problems. The result shows that RR-PSO_AENS has a computing speed which is 30 times faster than that of NSGA-II even though the later algorithm has a slightly smaller IGD value. Later, RR-PSO_ANS is implemented to several synthetic data and a field data. The yielded results shows that the solution (Pareto Front) of the developed algorithm has a close value to the True Pareto Front and able to provide the information about the model uncertainty through the retrieved Pareto Front model. The final solution gave an information about how good the RR-PSO_ANS is in estimating the parameters of 1D MT data with RMS values only of 10^{-2} - 10^{-3} for synthetic data, and less than 5 % for field data.

Keywords: 1D Magnetotelluric Inversion, ANS, Multiobjective, RR-PSO

KATA PENGANTAR

Puji syukur kehadiran Allah SWT yang selalu melimpahkan rahmat, hidayah, dan kasih sayang-Nya, yang selalu memberikan kemudan dan kelancaran dalam segala hal, sehingga Penulis dapat menyelesaikan Laporan Tugas Akhir dengan judul:

**“INVERSI DATA MAGNETOTELLURIK 1-D BERBASIS
RR-PSO DENGAN METODE SELEKSI *APPROXIMATE*
NON-DOMINATED SORTING (ANS)”**

sebagai syarat untuk menyelesaikan program studi jenjang Strata-1 Departemen Fisika ITS. Penulis menyadari bahwa terselesainnya penyusunan tugas akhir ini tidak terlepas dari bantuan dan dukungan dari berbagai pihak, maka pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Dr.rer.nat.Bagus Jaya Santosa dan Dr. Sungkono selaku dosen pembimbing dalam tugas akhir ini. Beliau telah memberikan banyak ilmu yang membantu Penulis selama perkuliahan dan sangat luar biasa dalam memberi bimbingan, wawasan, dan motivasi sehingga Penulis dapat menyelesaikan Tugas Akhir ini.
2. Bapak Dr. Yono Hadi P., M. Eng dan Dr.rer.nat. Eko Minarto, selaku Ketua Departemen dan Seketaris Departemen Fisika FMIPA ITS yang telah memberikan kemudahan sarana selama kuliah sampai terselesainnya Tugas Akhir ini.
3. Drs.Gontjang Prajitno,M.Si selaku dosen wali yang telah memberikan saran serta bimbingan berhubungan dengan perkuliahan selama masa belajar Penulis.
4. Keluarga tercinta, Ummi, Abi, Mas Himam, Mas Haidzar, Adik Ifna, yang senantiasa mendukung, mendoakan, menjadi penghibur, penyemangat dan motivasi Penulis dalam penyelesaian tugas akhir ini.
5. Kawan-kawan sebingingan dan seperjuangan Tugas Akhir Bidang Geofisika: Masyithah Noor W., Rijalul Fikri, Normasari Wijayanti dan Venny Revianti, terimakasih atas

semangat, motivasi, suka dan duka yang telah kita lalui selama masa penyelesaian Tugas Akhir ini.

6. Kawan senasib saat sedang penat, Elis Nuraini & Ning Rosianah.
7. Keluarga besar Fisika 2012 yang telah memberikan dukungan terbaik untuk penulis dan menjadi keluarga kedua bagi penulis selama masa belajar penulis di Departemen Fisika ITS.
8. Keluarga besar Laboratorium Geofisika Departemen Fisika ITS.
9. Semua pihak yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari bahwa dalam proses penyusunan laporan ini terdapat kesalahan. Sehingga penulis meminta kritik dan saran pembaca yang dapat membantu untuk menyempurnakan laporan ini. Akhir kata semoga Tugas Akhir ini bermanfaat bagi semua pihak. Aamiin Ya Rabbal Alamiin.

Surabaya, 25 Januari 2017

Haiyina Hasbia Amania

DAFTAR ISI

HALAMAN JUDUL	i
COVER PAGE	ii
LEMBAR PENGESAHAN.....	iii
ABSTRAK	iv
ABSTRACT.....	vi
KATA PENGANTAR	vii
DAFTAR ISI	ix
DAFTAR GAMBAR	xii
DAFTAR TABEL.....	xiv
DAFTAR LAMPIRAN	xv
BAB I PENDAHULUAN	17
1.1 Latar Belakang	17
1.2 Perumusan Masalah.....	20
1.3 Tujuan Penelitian.....	21
1.4 Batasan masalah	21
1.5 Manfaat penelitian	21
1.6 Sistematika Penulisan	21
BAB II TINJAUAN PUSTAKA	23
2.1 Metode Magnetotellurik	23
2.1.1 Sumber Magnetotellurik	24
2.1.2 Prinsip Dasar Magnetotellurik	25
2.2 Pemodelan Data Geofisika	29

2.3	<i>Multiobjective Optimization using Evolutionary Algorithm (MOEA)</i>	31
2.3.1	<i>Approximate Non-Dominated Sorting (ANS)</i>	34
2.4	<i>Particle Swarm Optimization (PSO)</i>	36
2.4.1	<i>Regressive- Regressive Particle Swarm Optimization (RR-PSO)</i>	38
2.5	Pemodelan Ke Depan Data Magnetotellurik 1-D.....	41
BAB III METODOLOGI		43
3.1	Peralatan dan Bahan	43
3.2	Prosedur Kerja.....	43
1.	Studi Literatur.....	43
2.	Modifikasi Algoritma	44
3.	<i>Algorithm Testing</i>	44
4.	<i>Forward Modeling</i>	44
5.	Pemodelan Inversi	44
6.	Uji Variasi Iterasi	46
7.	Analisa Data dan Pembahasan	47
BAB IV ANALISA DATA DAN PEMBAHASAN.....		49
4.1	Pengujian Algoritma.....	49
4.2	Pemodelan Ke Depan	53
4.3	Inversi Data Sintetik	57
4.4	Analisa Data Lapangan.....	64
4.5	Uji Variasi Iterasi	68
BAB V KESIMPULAN DAN SARAN.....		73
a.	Kesimpulan	73
b.	Saran.....	73

DAFTAR PUSTAKA	75
LAMPIRAN A.....	79

DAFTAR GAMBAR

Gambar 2. 1 Rentang resistivitas-konduktivitas berbagai material (Grandis, 2005).....	23
Gambar 2. 2 Terbentuknya medan elektromagnetik pada bumi karena solar wind (Simpson and Bahr, 2005)	25
Gambar 2. 3 Pemodelan data geofisika secara umum.....	29
Gambar 2. 4. Klasifikasi dari Optimasi Multi-Objektif (Talbi, 2009).....	32
Gambar 2. 5 Tahap pengerjaan Approximate Non-Dominated Sorting (ANS).....	35
Gambar 2. 6 Ilustrasi model bumi berlapis horizontal (Grandis, 2009).....	41
Gambar 2. 7 Prosedur pemodelan ke depan MT 1-D.....	42
Gambar 3. 1 Diagram Alir RR-PSO_ANS	46
Gambar 3. 2 Diagram Alir Penelitian	47
Gambar 4. 1 Kurva IGD terhadap Iterasi.....	51
Gambar 4. 2 Distribusi Pareto Front terhadap <i>True Pareto</i> (hitam) dari hasil aproksimasi menggunakan RR-PSO_ANS (merah) dan NSGA-II (biru) pada data set ZDT dengan 10 kali proses.....	52
Gambar 4. 3 Data MT sintetis 3 lapisan resistif diantara konduktif, (a) Resistivitas semu, (b) Fasa, (c) Resistivitas bawah permukaan.	54
Gambar 4. 4 Data MT sintetis 3 konduktif diantara resistif, (a) Resistivitas semu, (b) Fasa, (c) Resistivitas bawah permukaan.	55
Gambar 4. 5 Hasil pemodelan kedepan pada model 5 lapisan konduktif- resistif-konduktif-resistif-konduktif. (a) Resistivitas Semu dan (b) Fasa. Gambar (c) merupakan gambaran distribusi resistivitas bawah permukaan.	56
Gambar 4. 6 Hasil pemodelan kedepan pada model 5 lapisan dengan resistivitas yang meningkat dengan kedalaman. (a) Resistivitas Semu dan (b) Fasa. Gambar (c) merupakan gambaran distribusi resistivitas bawah permukaan.	57

Gambar 4. 7 Hasil inversi dengan algortima RR-PSO_ANS pada model 3 lapisan resistif diantara konduktif.	58
Gambar 4. 8 Hasil inversi dengan algortima RR-PSO_ANS pada model 3 lapisan resistif diantara konduktif.	59
Gambar 4. 9 Hasil inversi dengan algortima RR-PSO_ANS pada model 5 lapisan konduktif- resistif-konduktif-resistif-konduktif.	60
Gambar 4. 10 Hasil inversi dengan algortima RR-PSO_ANS pada model 5 lapisan resistif diantara konduktif.	60
Gambar 4.11 Profil bawah permukaan data lapangan. (a) Resistivitas semu, (b) fasa, (c) <i>skindepth</i>	65
Gambar 4. 12 Hasil Inversi RR-PSO_ANS terhadap data lapangan	66
Gambar 4. 13 Hasil inversi data sintetik dengan menggunakan 50 iterasi	69
Gambar 4. 14 Model hasil inversi RR-PSO_ANS dengan 50 iterasi.	70
Gambar 4. 15 Distribusi PF pada data 5 lapisan dengan 50 iterasi.	71
Gambar 4. 16 Distribusi PF pada data 5 lapisan dengan 150 iterasi.	72

DAFTAR TABEL

Tabel 4. 1 Hasil Pengujian algoritma RR-PSO_ANS dan NSGA-II (tulisan tebal menunjukkan hasil yang terbaik)	50
Tabel 4.2. Model lapisan yang digunakan dalam pembuatan data sintetik	53
Tabel 4. 3 Data nilai RMS hasil inversi dari keempat model pelapisan.....	61
Tabel 4. 4 <i>Best solution</i> hasil inversi keempat model sintetik	62
Tabel 4. 5 Estimasi ruang model pada data lapangan	65
Tabel 4. 6 Hasil terbaik implementasi inversi RR-PSO_ANS pada data lapangan.....	67

DAFTAR LAMPIRAN

LAMPIRAN A	Hasil Inversi RR-PSO_ANS dengan Variasi Iterasi	79
-------------------	---	----

“ halaman ini sengaja dikosongkan ”

BAB I

PENDAHULUAN

1.1 Latar Belakang

Lapisan penyusun bumi terdiri atas 3 lapisan utama yaitu kerak bumi, mantel bumi, dan inti bumi. Kerak bumi memiliki kedalaman sekitar 25 km dan mantel bumi diperkirakan memiliki kedalaman mencapai 2890 km (Campbell, 1987). Terdapat beberapa macam sumber daya alam yang terletak di bawah permukaan bumi. Untuk mendapatkan informasi mengenai apa yang ada di bawah permukaan bumi dan bagaimana karakter yang dimilikinya, perlu dilakukan survey geofisika untuk mengetahui nilai parameter-parameter fisis yang ditimbulkan oleh material-material dan struktur geologi yang ada di bawah permukaan bumi. Dengan menggunakan nilai parameter-parameter yang didapatkan dari survey geofisika, dapat dilakukan pemodelan lapisan bawah permukaan untuk mengetahui persebaran parameter fisis dan memperkirakan keadaan bawah permukaan. Salah satu parameter pengukuran yang dapat menggambarkan tentang keadaan fisis dan karakter penyusun lapisan ialah konduktivitas (Rokityansky, 1982). Melalui parameter ini, banyak informasi yang bisa didapatkan seperti material apa saja yang ada pada suatu lapisan, karakter kelistrikan batuan, zona-zona tertentu seperti zona reservoir, zona melting dan zona dehidrasi, dan masih banyak informasi lainnya.

Metode geofisika yang biasa digunakan untuk mengetahui parameter konduktivitas bumi adalah metode geolistrik. Namun sayangnya, jangkauan kedalaman pengukuran metode tersebut tidak terlalu dalam. Salah satu metode yang dapat menjangkau target survey pada kedalaman yang besar adalah magnetotellurik. Metode magnetotellurik (MT) merupakan metode geofisika berbasis elektromagnetik dengan jangkauan penetrasi yang bergantung pada frekuensi gelombang elektromagnet. Metode ini memanfaatkan medan elektromagnet alami bumi berupa arus eddy yang berasal dari petir atau radiasi solar wind. Dalam survey

MT, dilakukan pengukuran komponen medan magnet dan medan listrik bumi untuk kemudian diolah untuk mendapatkan nilai resistivitas semu dan fasa. Konduktivitas bawah permukaan dapat diamati melalui analisa data resistivitas.

Untuk mengetahui bagaimana distribusi resistivitas pada perlapisan bumi, diperlukan adanya pemodelan berdasarkan parameter tersebut. Ada dua jenis pemodelan yang bisa dilakukan, yaitu pemodelan ke depan (*forward modeling*) dan pemodelan inversi (*inverse modeling*). Permasalahan utama yang ada pada pemodelan geofisika adalah adanya solusi hasil yang tidak tunggal. Menurut Grandis (2009), penyebab ketidaktunggalan solusi pemodelan antara lain: 1). Sifat fisika dari fenomena yang ditinjau, 2). Adanya *noise*, dan 3). Kekurangan data untuk menjadi *constraint* solusi. Sampai saat ini, pengembangan dalam pemodelan data MT masih terus dilakukan. Beberapa teknik pemodelan yang digunakan untuk bisa mendapatkan hasil yang lebih cocok dengan data observasi sehingga dapat digunakan sebagai representasi keadaan bawah permukaan.

Model inversi non linear yang menggunakan pendekatan lokal cenderung menimbulkan masalah konvergensi dan membutuhkan model awal yang cukup dekat dengan solusi (Grandis, 2009). Solusi yang dihasilkan dengan menggunakan metode ini bersifat minimum lokal, sehingga seringkali hasil pemodelan bukanlah model optimum. Untuk menghindari hal tersebut, maka dilakukan pemodelan inversi yang menggunakan pendekatan global.

Terdapat beberapa metode yang bisa digunakan dalam menentukan minimum global, salah satunya adalah metode stokastik. Menurut Kan dan Timmer (1984), metode stokastik mampu menentukan baik minimum lokal maupun global. Dalam menentukan minimum global, metode stokastik menganalisa fungsi objektif dalam sejumlah sampel acak. Fungsi objektif yang digunakan dalam pencarian solusi optimum metode stokastik dapat berupa objektif tunggal atau multiobjektif (lebih dari satu fungsi objektif). Pada data magnetotellurik, terdapat dua

parameter yang akan diminimumkan, karena itu, digunakan teknik optimasi multiobjektif dalam penentuan solusi optimumnya.

Dalam optimasi multiobjektif, adanya lebih dari satu fungsi objektif menyebabkan proses komputasinya menjadi kurang efisien. Karena itu, pengembangan terhadap pendekatan-pendekatan yang lebih efisien terus dilakukan. Multiobjective Optimization Evolutionary Algorithm (MOEA) merupakan metode stokastik berbasis populasi dan merupakan metode sangat efektif dalam penentuan solusi optimum hanya dalam satu kali pemrosesan (Mashwani *et al.*, 2015). MOEA mengalami perkembangan dari waktu ke waktu. Ada beberapa jenis MOEA yang muncul diantaranya adalah MOEA berbasis *Pareto Dominance*, dekomposisi, Indikator, Seleksi Semetrik, dan masih ada beberapa lainnya. Namun demikian, jika jumlah objektif yang harus diminimumkan meningkat, maka keefektifan dari MOEA pun juga akan semakin menurun. Dari masalah tersebut, pencarian pendekatan-pendekatan baru yang lebih efektif terus dilakukan. Penelitian serupa dilakukan oleh Ramadhani (2016) dengan menggunakan NSGA-II. Hasil inversi dari penelitian ini menunjukkan bahwa NSGA-II memiliki kualitas solusi yang bagus dalam penyelesaian masalah optimasi multiobjektif, hanya saja, waktu yang dibutuhkan dalam proses inversinya cukup lama. Pramudiana (2016) juga melakukan penelitian untuk mengoptimasi permasalahan multiobjektif dengan menggunakan algoritma Multi-objektif Dragonfly dan menghasilkan solusi optimum yang bagus dalam penentuan parameter fisis pada data magnetotellurik 1D. Kedua penelitian tersebut menunjukkan bahwa meskipun MOEA memiliki kemampuan yang unggul dalam menyelesaikan permasalahan multiobjektif, perlu dilakukan suatu peningkatan kualitas performa dari MOEA saat fungsi objektif yang akan diminimumkan bertambah.

Salah satu MOEA yang beberapa tahun belakangan ini sering digunakan adalah algoritma *Particle Swarm Optimization* (PSO). PSO menjadi salah satu metode yang menjanjikan karena

kecepatannya dalam pencarian solusi optimum. Dalam beberapa dekade terakhir, muncul algoritma-algoritma baru yang didapat dari pengembangan PSO, salah satunya adalah *Regressive-Regressive Particle Swarm Optimization* (RR-PSO). Diantara varian PSO lainnya, RR-PSO merupakan algoritma yang memiliki beberapa keunggulan, diantaranya adalah kemampuan eksplorasi dalam ruang pencarian solusi yang lebih baik seperti yang diungkapkan oleh Fernandez-Martinez et al. Selain itu, RR-PSO juga memiliki tingkat konvergensi yang tinggi dan kecepatan dalam penentuan solusi optimum pada suatu fungsi objective (Laby et al., 2016).

Zhang et al. (2016) memperkenalkan *Approximate Non-dominated Sorting* (ANS), sebuah pendekatan Non-dominated sorting yang mana prosedur ini bekerja dengan cara mengelompokkan solusi yang ada berdasarkan hubungan *Pareto Dominance*-nya. Dari penelitian yang dilakukan, pendekatan ANS ternyata membuat proses komputasi lebih efisien dalam menyelesaikan masalah multiobjektif dengan melakukan perbandingan tiga objektif diantara dua solusi yang ada untuk menentukan hubungan dominasinya.

Lamanya proses komputasi dalam optimasi multiobjektif seiring dengan bertambahnya fungsi objektif yang ada menjadi suatu masalah yang harus dipecahkan. Penambahan metode ANS pada RR-PSO ditujukan untuk mencapai suatu metode optimasi multiobjektif yang dapat tetap beroperasi dengan cepat dalam penentuan solusi optimum meskipun jumlah parameter yang digunakan bertambah.

1.2 Perumusan Masalah

Berdasarkan latar belakang di atas, maka dapat dirumuskan permasalahan dalam penelitian ini yaitu:

1. Bagaimana hasil inversi dari algoritma RR-PSO_ANS
2. Bagaimana kemampuan algoritma RR-PSO_ANS dalam menentukan parameter fisis data magnetotellurik 1D pada berbagai model lapisan.

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Mengetahui hasil inversi dari algoritma RR-PSO ANS
2. Mengetahui kemampuan algoritma RR-PSO_ANS dalam menentukan parameter fisis data magnetotellurik 1D pada berbagai model lapisan.

1.4 Batasan masalah

Pada penelitian ini, memiliki batasan masalah sebagai berikut:

1. Metode optimasi dalam proses inversi yang digunakan adalah algoritma RR-PSO_ANS
2. Data yang digunakan dalam penelitian ini adalah data magnetotellurik 1-D
3. Terdapat Asumsi-asumsi data magnetotellurik 1D yang harus dipatuhi

1.5 Manfaat penelitian

Penelitian ini diharapkan dapat memberikan gagasan mengenai pengembangan algoritma RR-PSO dengan metode seleksi individu ANS untuk menghasilkan algoritma yang lebih efisien dan akurat dalam permasalahan inversi data geofisika.

1.6 Sistematika Penulisan


Pada penulisan Tugas Akhir ini terdiri dari abstrak yang menggambarkan tentang gambaran umum dari penelitian ini. Bab I yang berisikan tentang latar belakang, perumusan masalah, tujuan penelitian, batasan masalah, manfaat penelitian dan sistematika penulisan. Bab II berisikan tentang tinjauan pustaka yang berkaitan dengan dasar teori sebagai acuan dari penelitian. Bab III berisikan tentang metodologi. Bab IV berisikan tentang hasil penelitian dan pembahasannya. Dan Bab V berisikan tentang kesimpulan dan saran.

“halaman ini sengaja dikosongkan”

BAB II TINJAUAN PUSTAKA

2.1 Metode Magnetotellurik

Metode magnetotellurik (MT) adalah suatu metode dari geofisika yang bersifat pasif yang memanfaatkan medan elektromagnetik alami sebagai sumber gelombang atau energi untuk mengetahui struktur tahanan jenis bawah permukaan. Metode ini dapat digunakan untuk menentukan sifat listrik bahan pada kedalaman yang relatif besar di dalam bumi. Perbedaan pada sinyal tercatat digunakan untuk memperkirakan distribusi resistivitas listrik bawah permukaan. Medan elektromagnetik yang digunakan mempunyai rentang frekuensi yang panjang sehingga mampu menyelidiki bawah permukaan dari kedalaman puluhan hingga ribuan meter.



Gambar 2. 1 Rentang resistivitas-konduktivitas berbagai material
(Grandis, 2005)

Gambar 2.1 merupakan suatu diagram yang menggambarkan tentang rentang nilai resistivitas dan konduktivitas dari berbagai material dan fluida. Dengan adanya perbedaan resistivitas pada bawah permukaan, maka struktur yang


ada pada perlapisan bawah permukaan juga akan lebih mudah untuk dianalisa.

2.1.1 Sumber Magnetotellurik

Sumber-sumber medan elektromagnetik yang digunakan bersumber dari petir dan matahari. Medan elektromagnet dengan frekuensi tinggi (>1 Hz) berasal dari aktivitas meteorologis berupa petir. Petir terjadi akibat adanya perbedaan potensial antara awan yang satu dengan awan yang lainnya atau antara awan dengan bumi. Proses terjadinya muatan pada awan disebabkan oleh pergerakan awan yang terus menerus dan teratur. Selama pergerakannya awan akan berinteraksi dengan awan yang lainnya sehingga muatan negatif akan berkumpul pada salah satu sisi awan, sedangkan muatan positif akan berkumpul pada salah satu sisi lainnya. Jika perbedaan potensial antara awan dan bumi cukup besar, maka akan terjadi pembuangan muatan negatif dari awan ke bumi atau sebaliknya untuk mencapai kesetimbangan. Petir yang terjadi di suatu tempat akan menimbulkan gelombang elektromagnet yang terperangkap diantara lapisan ionosfer dan bumi (wave guide) dan kemudian menjalar mengitari bumi. Sumber medan elektromagnetik yang lain adalah *solar wind*. *Solar wind* memiliki rentang frekuensi kurang dari 1 Hz (Simpson and Bahr, 2005).

Gambar 2.2 menggambarkan bagaimana proses terjadinya medan elektromagnetik di Bumi yang diakibatkan oleh *solar wind*. *Solar wind* ini bersumber dari plasma matahari yang membawa proton dan elektron, berhembus secara terus menerus ke arah bumi dengan intensitas yang berbeda. Ketika *solar wind* ini bersentuhan dengan magnetopause bumi, maka proton dan elektron yang dibawa olehnya akan berpecah ke arah yang berbeda dan menimbulkan arus listrik dan medan magnet. Adanya variasi densitas, kecepatan dan intensitas medan magnet *solar wind* akan menyebabkan distorsi pada magnetopause. Medan elektromagnet yang dihasilkan oleh *solar wind* akan terus menjalar menuju ionosfer dan berinteraksi dengan partikel-

partikel yang berada di dalamnya sehingga menyebabkan timbulnya gelombang elektromagnet yang mengalir pada ionosfer dan terus menjalar ke permukaan bumi. Gelombang elektromagnet yang berhasil menembus permukaan bumi akan berinteraksi dengan material-material dalam bumi yang dapat menyebabkan timbulnya arus eddy (Hakim dkk, 2014).



Gambar 2. 2 Terbentuknya medan elektromagnetik pada bumi karena solar wind (Simpson and Bahr, 2005)

2.1.2 Prinsip Dasar Magnetotellurik

Terdapat beberapa asumsi dasar yang harus dipatuhi dalam mengkaji tentang Metode magnetotellurik sebagaimana yang telah dijelaskan oleh Simpson dan Bahr (2005). Asumsi-asumsi tersebut meliputi:

1. Persamaan yang digunakan adalah Persamaan Maxwell.

2. Bumi hanya menyerap dan menyebarkan medan elektromagnetik yang mengalir padanya dan tidak menghasilkan medan elektromagnetik dengan sendirinya.
3. Semua medan yang berada di dalam bumi dianggap sebagai medan konservatif dan dapat diamati jauh dari sumbernya.
4. Sumber medan elektromagnetik adalah medan elektromagnetik alami yang dihasilkan dari proses meteorologi (petir) maupun dari *solar wind* dan dianggap *uniform*.
5. Tidak terdapat akumulasi muatan bebas pada setiap lapisan bumi.
6. Bumi dianggap sebagai medium konduktif yang dapat menghantarkan arus listrik.
7. Medan perpindahan elektrik bersifat *quasi-static* untuk periode perekaman MT.
8. Variasi permitivitas dan permeabilitas listrik dari batuan dianggap tidak ada.

Metode magnetotellurik ini menggunakan dasar Persamaan Maxwell yang merupakan persamaan dasar untuk fenomena-fenomena listrik-magnet. Persamaan Maxwell diberikan oleh:

$$\nabla \times E = -\frac{\partial B}{\partial t} \quad (2.1)$$

$$\nabla \times H = j_f + \frac{\partial D}{\partial t} \quad (2.2)$$

$$\nabla \cdot D = \eta_f \quad (2.3)$$

$$\nabla \cdot B = 0 \quad (2.4)$$

dengan B adalah fluks magnetik, E dan H berturut – turut adalah medan listrik dan medan magnet, η_f merupakan rapat muatan listrik, D adalah perpindahan listrik, dan j_f adalah rapat arus.

Parameter-parameter pada Persamaan Maxwell tersebut memiliki hubungan:

$$B = \mu H \quad (2.5)$$

$$D = \varepsilon E \quad (2.6)$$

$$j = \sigma E = \frac{E}{\rho} \quad (2.7)$$

dengan σ adalah konduktivitas listrik, μ adalah permeabilitas magnetik, ε merupakan permitivitas listrik, dan ρ adalah tahanan jenis.

Sebagai upaya untuk menyederhanakan masalah, medium dianggap bersifat homogen isotropis. Selanjutnya digunakan pendekatan keadaan kuasistatik dimana harga dari ε dapat diabaikan terhadap σ dan μ karena $\omega\mu\sigma \gg \omega^2\mu\varepsilon$ untuk $\mu = \mu_0 = 4\pi$ dan akan diperoleh Persamaan Helmholtz sebagai berikut (Grandis, 2009):

$$\nabla^2 = \mu_0 \sigma \frac{\partial E}{\partial t} \quad (2.8)$$

$$\nabla^2 = \mu_0 \sigma \frac{\partial H}{\partial t} \quad (2.9)$$

Dilakukan juga penyederhanaan persamaan terhadap waktu dan dihasilkan persamaan difusi:

$$\nabla^2 E = k^2 E \quad (2.10)$$

$$\nabla^2 H = k^2 H \quad (2.11)$$

dengan nilai bilangan gelombang $k = \pm \sqrt{i\omega\mu_0\sigma}$.

Prinsip kerja dari metode ini adalah proses induksi elektromagnetik yang terjadi pada anomali bawah permukaan. Medan elektromagnet yang menembus bawah permukaan akan menginduksi anomali konduktif bawah permukaan bumi

sehingga menghasilkan E dan magnetik sekunder (arus eddy), yang kemudian akan direkam oleh alat magnetotellurik. Gelombang elektromagnetik yang menembus permukaan bumi akan mengalami peluruhan amplitudo terhadap kedalaman dan akan memberikan besar *skin depth* (δ). *Skin depth* merupakan kedalaman suatu medium dimana amplitudo gelombangnya sudah mengalami atenuasi, yaitu pelemahan gelombang akibat jarak yang semakin jauh atau dalam. Persamaan *skin depth* diberikan oleh:

$$\delta = \sqrt{\frac{2\rho}{\omega\mu_0}} \quad (2.12)$$

Berdasarkan pada sifat penjalaran medan elektromagnet pada anomaly konduktif, kedalaman penetrasi bergantung pada frekuensi dan resistivitas material bawah permukaan. Material yang memiliki resistivitas yang kecil mempunyai daya tembus yang kecil, dan medan elektromagnet yang mempunyai frekuensi yang tinggi mempunyai daya tembus yang kecil.

Pada metode magnetotellurik terdapat parameter fisis yang disebut dengan impedansi (Z). Impedansi merupakan perbandingan antara komponen medan listrik dan medan magnet yang saling tegak lurus. Pada model bumi homogen (1-D) persamaan impedansi diberikan oleh:

$$Z_{xy} = \frac{E_x}{H_y} = \sqrt{i\omega\mu_0\rho} \quad (2.13)$$

Dengan persamaan resistivitas dan fasa berupa


$$\rho = \frac{1}{\omega\mu_0} |Z|^2 \quad (2.14)$$

$$\phi = \tan^{-1} \left(\frac{\text{Im} Z}{\text{Re} Z} \right) \quad (2.15)$$

dimana pada model bumi homogen (1-D) E dan H tidak dipengaruhi oleh arah x dan y ($Z_{xy} = -Z_{yx}$; $Z_{xx} = Z_{yy} = 0$) (Wahyu dkk, 2013).

2.2 Pemodelan Data Geofisika

Pengukuran lapangan dilakukan dengan tujuan untuk mengetahui kondisi pada daerah tersebut. Pada survey geofisika, data lapangan yang didapatkan digunakan untuk mengekstrak informasi keadaan bawah permukaan. Untuk mengetahui bagaimana keadaan bawah permukaan, perlu dilakukan adanya proses pemodelan terhadap parameter-parameter terukur yang ada pada data lapangan. Pada pemodelan data geofisika, diperkenalkan dua jenis metode pemodelan yaitu pemodelan ke depan (*forward modeling*) dan pemodelan inversi.



Gambar 2. 3 Pemodelan data geofisika secara umum

Forward modeling merupakan sebuah proses pemodelan dimana dilakukan prediksi terhadap data observasi dengan menggunakan parameter fisis yang sudah diketahui, sebagaimana yang disajikan pada Gambar 2.3. Tarantola (2005) mendefinisikan *forward modeling* sebagai suatu hukum fisika yang memungkinkan untuk membuat prediksi hasil pengukuran

dengan menggunakan parameter observasi. Proses *forward modeling* ini merupakan proses iterasi yang cukup rumit dengan melibatkan *trial and error* pada parameter data untuk mengetahui di bagian data mana yang terdapat *misfit* untuk kemudian dimodifikasi sampai menemukan data yang *fit* dengan data observasi.

Jika dalam *forward modeling* dilakukan prediksi data berdasarkan model, maka yang sebaliknya terjadi pada pemodelan inversi. Pada pemodelan inversi dilakukan penentuan dan estimasi parameter model langsung berdasarkan data lapangan (Menke, 1984). Dalam pemodelan inversi, dilakukan pencarian solusi optimum dari model dengan cara meminimumkan fungsi objektif pada data dengan menggunakan teknik penyelesaian secara matematis dan statistik. Supriyanto (2007) menjelaskan pemodelan inversi dilakukan untuk mengesitimasi parameter fisis batuan yang belum diketahui sebelumnya dengan melakukan *curve fitting* antara model matematika dan data lapangan. Secara umum, permasalahan dalam pemodelan inversi dapat dinyatakan oleh (Martinez *et al.*, 2012):

$$\mathbf{F}(\mathbf{m}) = \mathbf{d} \quad (2.16)$$

dimana \mathbf{m} , \mathbf{d} , dan $\mathbf{F}(\mathbf{m})$ berturut-turut adalah parameter model, data observasi, dan representasi model kedepan. Penyelesaian masalah inversi tersebut diharapkan dapat memberikan hasil nilai parameter \mathbf{m} yang unik. Namun terdapat beberapa faktor yang membuat solusi yang dihasilkan menjadi tidak unik Fernandez-Martinez *et al.* (2012), diantaranya adalah model kedepan adalah penyederhanaan dari keadaan sesungguhnya, dan data observasi selalu mengandung *noise*.

Noise yang terdapat dalam data dapat memengaruhi bentuk pemodelan. Dalam beberapa kasus, adanya *noise* pada data dapat meningkatkan jumlah minimum lokal yang dapat membuat seleksi solusi optimum menjadi tidak mudah. Metode optimasi dengan menggunakan minimum lokal tidak dapat menyelesaikan permasalahan seperti ini, oleh karena itu kemudian

dilakukan pendekatan dengan menggunakan optimasi minimum global. Terdapat berbagai macam metode optimasi global yang dapat digunakan dalam menyelesaikan permasalahan inversi, beberapa diantaranya adalah *Multiobjective Optimization Evolutionary Algorithm* (MOEA) dan *Particle Swarm Optimization* (PSO).

2.3 *Multiobjective Optimization using Evolutionary Algorithm (MOEA)*

Pemodelan inversi non-linear cenderung fokus pada pencarian minimum lokal. Pada suatu pemodelan, sangat mungkin apabila terdapat lebih dari satu nilai minimum lokal yang muncul, dan hal ini menjadi penyebab ketidakunikan pada solusi pemodelan. Semakin banyak minimum lokal yang muncul dapat membuat kemungkinan solusi terjebak pada minimum lokal semakin besar, sementara fungsi optimum yang diinginkan berada pada minimum global. Untuk menghindari hal tersebut, maka dilakukan pemodelan inversi non-linier yang menggunakan pendekatan global.


Terdapat beberapa metode yang bisa digunakan dalam menentukan minimum global, salah satunya adalah metode stokastik. Metode stokastik mampu menyelesaikan masalah yang berkaitan dengan *noise* pada suatu data, sistem non-linier, sistem berdimensi tinggi, atau pada permasalahan yang tidak dapat diselesaikan dengan metode deterministik klasik (Spall, 2012). Menurut Kan and Timmer (1984), metode stokastik mampu menentukan baik minimum lokal maupun global. Dalam menentukan minimum global, metode stokastik menganalisa fungsi objektif dalam sejumlah sampel acak. Fungsi objektif yang digunakan dalam pencarian solusi optimum metode stokastik dapat berupa objektif tunggal atau multiobjektif (lebih dari satu fungsi objektif). Pada data yang memiliki dua parameter atau lebih dapat menggunakan optimasi multiobjektif dalam penentuan solusi optimumnya.

Optimasi multiobjektif menitikberatkan pada permasalahan meminimumkan lebih dari satu fungsi objektif. Secara matematis, persamaan untuk optimasi multiobjektif diberikan oleh:

$$\text{minimize } [f_1(x), f_2(x), \dots, f_n(x)]^T \quad (2.17)$$

$$x \in \Omega$$

dengan Ω merupakan ruang ketetapan, $x = (x_1, x_2, \dots, x_n)^T$ merupakan individual atau solusi, dan $x_i, i = 1, 2, \dots, n$ adalah variabel ketetapan.



Gambar 2. 4. Klasifikasi dari Optimasi Multi-Objektif (Talbi, 2009)

Gambar 2. 4 menunjukkan berbagai jenis algoritma yang digunakan dalam optimasi multiobjektif. Berdasarkan pendekatan yang dilakukan, optimasi multiobjektif dibagi menjadi tiga yaitu optimasi dengan menggunakan pendekatan (Talbi, 2009): 1) *a priori*, dimana pembuat ketetapan memberikan pilihan solusi sebelum proses optimasi berlangsung dan biasanya

menggabungkan beberapa fungsi objektif untuk mendapatkan satu fungsi objektif yang akan dioptimasi, 2) interaktif, dimana terdapat interaksi progresif antara pembuat ketetapan dan pemecah solusi, 3) *a posteriori*, yang mana pada pendekatan ini, pembuat ketetapan dilibatkan setelah proses pencarian pada pendekatan *a posteriori* untuk menentukan solusi Pareto optimal dari fungsi objektif.

Pada optimasi multiobjektif *a posteriori*, pendekatan yang sering digunakan dalam menentukan solusi Pareto adalah pendekatan berbasis algoritma evolusioner. *Multiobjective Optimization Evolutionary Algorithm (MOEA)* dianggap sangat efektif dalam menentukan solusi Pareto hanya dalam satu kali pemrosesan (Mashwani *et al.*, 2015). Adapun tujuan dari pendekatan ini adalah untuk menentukan model parameter yang memberikan solusi Pareto sebaik mungkin dengan fungsi dua fungsi objektif atau lebih. Namun demikian, proses pencarian solusi optimum yang diinginkan bisa menjadi proses yang rumit. Apabila jumlah objektif yang harus diminimumkan meningkat, maka keefektifan komputasi dari MOEA pun juga akan semakin menurun. Dari masalah tersebut, pencarian pendekatan-pendekatan baru yang lebih efektif terus dilakukan untuk menyelesaikan masalah-masalah multiobjektif yang lebih kompleks.


Dari waktu ke waktu, pengembangan MOEA terus dilakukan. MOEA berbasis dominasi menjadi salah satu penyelesaian multiobjektif yang efektif dalam menyelesaikan masalah pada optimasi multiobjektif kompleks. MOEA berbasis dominasi pertama kali dikenalkan oleh Goldberg (1989) dalam algoritma genetik (GA). Beberapa hasil pengembangan MOEA yang paling populer (Khan *et al.*, 2015) antara lain adalah *Non-dominated Sorting Genetic Algorithm (NSGA-II)*, *Strength Pareto-Evolutionary Algorithm (SPEA2)*, *Pareto Archive Evolution Strategy (PAES)*, *Multi-Objective Genetic Algorithm (MOGA)*, dan *Niched Pareto Genetic Algorithm (NPGA)*.

Menurut Zhang et.al (2016), timbul dua masalah baru yang muncul dari MOEA berbasis dominasi. Pertama, seiring dengan bertambahnya fungsi objektif, maka penentuan kualitas solusi juga akan menurun, menyebabkan pencarian individu untuk solusi Pareto menjadi menurun. Kedua, dengan bertambahnya waktu pemrosesan data yang dibutuhkan pada metode *non-dominated sorting* akan menyebabkan efisiensi dari MOEA menurun. Sehingga, ia mengembangkan sebuah pendekatan baru yaitu *Approximate Non-Dominated Sorting* (ANS) dengan tujuan untuk mengurangi *runtime* dan meningkatkan efisiensi pada permasalahan optimasi multiobjektif yang memiliki lebih dari dua fungsi objektif.

2.3.1 *Approximate Non-Dominated Sorting* (ANS)

Kebanyakan dari metode-metode MOEA berbasis dominasi bermasalah pada besarnya *runtime* yang dibutuhkan sehingga mengurangi efisiensi dari algoritma tersebut. Tujuan utama dari dilakukannya perbaikan pada algoritma-algoritma yang sudah ada sebenarnya adalah untuk mengurangi jumlah perbandingan dominasi yang berlebihan pada setiap kali *run* sebanyak mungkin. Jika terdapat dua solusi dengan M buah fungsi objektif, maka perbandingan yang harus dilakukan setidaknya minimal dua fungsi objektif dan maksimal M buah fungsi objektif. Hal inilah yang menyebabkan menurunnya efisiensi pada MOEA saat fungsi objektifnya bertambah. Sehingga, Zhang et.al (2016) kemudian mengembangkan algoritma *Approximate Non-Dominated Sorting* (ANS) yang diharapkan dapat menyelesaikan permasalahan tersebut.

Approximate Non-Dominated Sorting (ANS) merupakan improvisasi dari algoritma *Efficient Non-dominated Sorting* (ENS). Pada ANS, penentuan hubungan *Pareto Dominance* (PD) dilakukan hanya dengan membandingkan paling banyak tiga fungsi objektif saja. Jika setelah dilakukan perbandingan tiga fungsi objektif dan PD masih belum bisa ditentukan, maka solusi yang sudah berada pada suatu *non-dominated front* akan dianggap mendominasi solusi yang akan ditempatkan pada *front* tersebut.



Gambar 2. 5 Tahap pengerjaan Approximate Non-Dominated Sorting (ANS).

Secara garis besar, prosedur kerja dari ANS disajikan pada Gambar 2.5. Misalkan terdapat M buah fungsi objektif yang harus diminimumkan dengan MOEA berpopulasi N . Pertama, ANS akan mengelompokkan N buah solusi berdasarkan solusi pertama secara urut. Jika urutan populasi tersebut adalah p_1, p_2, \dots, p_N , maka objektif pertama dari p_i akan selalu lebih kecil atau sama dengan objektif pertama dari p_j , jika $i < j$ dengan $1 \leq i, j \leq N$. Sehingga akan berlaku p_i mendominasi p_j atau keduanya saling tidak mendominasi satu sama lain. Selanjutnya, ANS akan menormalisasi semua solusi sebelum melakukan *sorting* pada populasi P dengan menggunakan nilai minimum dan maksimum dari tiap objektif. Untuk semua solusi $p = (f_1, f_2, \dots, f_N)$, maka solusi ternormalisasi solusi $p' = (f_1', f_2', \dots, f_N')$, dengan:

$$f_i' = \frac{(f_i - f_{\min})}{(f_{\max} - f_{\min})} \quad (2.18)$$

Setelah normalisasi, kemudian dilakukan identifikasi dua fungsi objektif yang dimulai dari fungsi kedua M fungsi objektif untuk digunakan dalam perbandingan fungsi objektif dalam penentuan PD. Selanjutnya dilakukan penempatan solusi ke *front* pertama (F_1). Solusi pertama p_1 selalu berada pada F_1 . Untuk solusi selanjutnya, jika tidak terdominasi oleh p_1 maka akan dimasukkan kedalam F_1 , tapi sebaliknya jika terdominasi oleh p_1 , maka solusi tersebut akan tetap berada di populasi. Kemudian ANS akan menempatkan solusi-solusi yang masih ada ke *front* yang lain. Tahapan ini terus dilakukan sampai semua solusi pada populasi berada pada sebuah *front*.

2.4 Particle Swarm Optimization (PSO)

Satu lagi metode stokastik yang dapat digunakan dalam permasalahan optimasi global, yaitu *Particle Swarm Optimization* (PSO). PSO merupakan anggota *evolutionary algorithm* (EA) yang menggunakan dasar paradigma *swarm intelligence*. Kennedy dan Eberhart (1995) menjelaskan bahwa terdapat lima prinsip dasar dari *swarm intelligence* menurut penelitian dari Millonas (1994) meliputi: 1) jarak atau kedekatan, 2) kualitas, 3) perbedaan respon, 4) stabilitas, dan 5) adaptabilitas.

Algoritma PSO ini terinspirasi oleh perilaku sosial hewan berkelompok seperti burung dan ikan saat mencari makan. PSO yang dikembangkan oleh Kennedy dan Eberhart (1995) adalah sebuah algoritma yang sederhana namun sangat efektif dan efisien dengan hanya membutuhkan beberapa operator matematis sederhana serta tidak memakan banyak memori penyimpanan dan waktu. Tujuan awal diusulkannya algoritma ini adalah untuk menyimulasikan gerakan dari sekawanan burung yang tidak menentu, seperti tiba-tiba berubah arah, berpencar, dan kemudian kembali berkelompok secara grafik. Simulasi awal yang merupakan simulasi lingkungan social kelompok hewan kemudian dimodifikasi untuk menggabungkan kecocokan kecepatan tetangga terdekat, menghilangkan variable tambahan,

serta menggabungkan pencarian multidimensi dan percepatan berdasarkan jarak (Eberhart and Shi, 2001).

Algoritma PSO memiliki kemiripan dengan algoritma genetik yaitu mengawali sistem dengan suatu populasi dari solusi acak. Namun demikian, PSO memiliki beberapa kelebihan tersendiri dibandingkan dengan algoritma genetik. Eberhart *et al.* (1995) mengungkapkan bahwa pada PSO, adanya interaksi pada populasi justru akan membuat semakin dekat dengan solusi yang dituju. Kemudian PSO juga memiliki *memory*, suatu aspek yang tidak dimiliki oleh algoritma genetik.

Pada PSO, tiap-tiap solusi potensial atau partikel, dalam konteks ini diasumsikan sebagai sekawanan burung, diberikan suatu kecepatan acak dan kemudian dilepaskan ke dalam ruang multidimensi. Sekawanan burung yang mencari makan secara acak akan mengikuti anggotanya yang memiliki posisi terdekat dengan makanan. Dari keadaan ini sekawanan burung tersebut mendapatkan posisi terbaiknya (*pbest*). Lalu anggota populasi ini akan mengingat posisi bagus tersebut dan kemudian menginfokannya ke anggota sekawanan lainnya yang kemudian akan mengikutinya menuju sumber makanan tersebut. Hal ini terus berulang sampai benar-benar ditemukan posisi sumber makanan yang paling bagus (*gbest*).

Adapun prosedur penerapan dari optimasi global PSO menurut (Eberhart and Shi, 2001) adalah sebagai berikut:

1. Menentukan populasi partikel dengan kecepatan dan posisi acak pada dimensi D diruang masalah
2. Mengevaluasi fungsi *fitness* optimasi yang diinginkan untuk tiap partikel
3. Membandingkan evaluasi *fitness* partikel dengan *pbest* partikel
4. Membandingkan evaluasi *fitness* dengan *gbest*
5. Mengubah kecepatan dan posisi partikel dengan berdasarkan:

$$v_{id+1} = v_{id} + c_1 * rand() * (p_{gd} - x_{id}) +$$

$$c_2 \text{rand}() * (p_{id} - x_{id})$$

$$x_{id+1} = x_{id} + v_{id} \quad (2.19)$$

6. Pengulangan langkah kedua sampai ditemukan *fitness* yang bagus.

PSO memiliki beberapa keunggulan dibandingkan dengan algoritma-algoritma lainnya diantaranya adalah implementasi yang sederhana, tidak memiliki perhitungan yang *overlapping*, dapat diselesaikan lebih mudah, kecepatan pencarian solusi optimum sangat cepat, dan mengadopsi kode bilangan real yang ditentukan langsung oleh solusi (Rini *et al.*, 2011). Disamping itu, PSO juga masih memiliki beberapa kelemahan yang perlu diperbaiki seperti mudah terjebak pada minimum lokal jika berada pada ruang berdimensi tinggi, serta tingkat konvergensi yang rendah pada proses iterasi (Li *et al.*, 2014).

Dari kekurangan-kekurangan yang dimiliki oleh PSO ini kemudian mendorong adanya improvisasi dari algoritma tersebut. PSO kemudian mulai dikembangkan dan muncul generasi varian PSO yang dapat digunakan dalam berbagai permasalahan, diantaranya adalah *Generalized Particle Swarm Optimization* (GPSO), *Centered-Centered Particle Swarm Optimization* (CC-PSO), *Progressive- Progressive Particle Swarm Optimization* (PP-PSO) , dan *Regressive-Regressive Particle Swarm Optimization* (RR-PSO).

2.4.1 *Regressive- Regressive Particle Swarm Optimization (RR-PSO)*

Regressive-Regressive Particle Swarm Optimization (RR-PSO) merupakan salah satu varian dari algoritma PSO yang dikembangkan oleh Fernandez-Martinez *et al.* (2010) melalui penurunan PP-GSO terhadap model kontinu PSO pada kasus PSO dengan $\Delta t=1$:

$$\begin{cases} x''(t) + (1 - \omega)x'(t) + \phi x(t) = \phi_1 g(t - t_0) + \phi_2 l(t - t_0), \\ x(0) = x_0, \\ x'(0) = v_0, \\ t \in R \end{cases}$$

dengan menggunakan diskritisasi regresi pada percepatan dan kecepatan. Fernandez-Martinez et al. (2010) merumuskan algoritma RR-PSO secara matematis sebagai berikut:

$$\begin{aligned} x'(t) &\approx \frac{x(t) - x(t - \Delta t)}{\Delta t} \\ x''(t) &\approx \frac{x(t) - 2x(t - \Delta t) + x(t - 2\Delta t)}{\Delta t^2} = \frac{x(t) - x'(t - \Delta t)}{\Delta t} \end{aligned} \quad (2.20)$$

Pada persamaan tersebut berlaku hubungan:

$$\begin{aligned} x(t) &= x(t - \Delta t) + v(t)\Delta t, \\ \frac{v(t) - v(t - \Delta t)}{\Delta t} + (1 - \omega)v(t) + \phi(x(t - \Delta t)) \\ &+ v(t)\Delta t = \phi_1 g(t - t_0) + \phi_2 l(t - t_0) \end{aligned} \quad (2.21)$$

Sehingga $v(t)$ dapat dituliskan menjadi:

$$v(t) = \frac{v(t - \Delta t) + \phi_1 \Delta t (g(t - t_0) - x(t - \Delta t))}{1 + (1 - \omega) \Delta t + \phi \Delta t^2} + \frac{\phi_2 \Delta t (l(t - t_0) - x(t - \Delta t))}{1 + (1 - \omega) \Delta t + \phi \Delta t^2} \quad (2.22)$$

Sehingga untuk keadaan dimana $\Delta t = 1$ didapatkan algoritma RR-PSO:

$$v(t + \Delta t) = \frac{v(t) + \phi_1 \Delta t (g(t) - x(t)) + \phi_2 \Delta t (l(t) - x(t))}{1 + (1 - \omega) \Delta t + \phi \Delta t^2},$$

$$x(t + \Delta t) = x(t) + v(t + \Delta t) \Delta t \quad (2.23)$$

dengan $\phi = \phi_1 + \phi_2$, kemudian $(1 - \omega)$, g , l , ϕ_1 , ϕ_2 , ω masing masing adalah konstanta kekakuan, posisi g_{best} , posisi l_{best} , random global dan percepatan lokal, serta bobot inersia. Dibandingkan dengan varian PSO lainnya, RR-PSO memiliki kelebihan pada beberapa aspek seperti kemampuan eksplorasi dan tingkat konvergensi yang lebih bagus serta penentuan parameter yang lebih mudah.

Dalam algortima RR-PSO yang digunakan, terdapat proses mutasi yang berfungsi untuk menghasilkan generasi baru. Hal ini ditujukan untuk menambah kemampuan algoritma dalam pencarian solusi optimum dan menghindari terjebaknya solusi pada minimum lokal dengan menghambat konvergensi. Secara matematis, persamaan mutasi diberikan sebagai berikut (Seshadri, 2006):

$$c_k = p_k + (p_k^u - p_k^l) \delta_k \quad (2.24)$$


dimana c_k adalah partikel yang dihasilkan dari proses mutasi dan p_k adalah partikel orang tua dari hasil mutasi. p_k^u dan p_k^l merupakan batas atas dan batas bawah dari p_k , dan δ_k adalah suatu variasi yang dihitung dengan menggunakan persamaan :

$$\delta_k = \begin{cases} (2r_k) \frac{1}{\eta_{m+1}} - 1, & r_k < 0.5 \\ 1 - [2(1 - r_k) \frac{1}{\eta_{m+1}}], & r_k > 0.5 \end{cases} \quad (2.25)$$

dengan r_k adalah angka acak *uniform* yang berada pada interval 0-1 dan η_m merupakan indeks distribusi mutasi.

2.5 Pemodelan Ke Depan Data Magnetotellurik 1-D

Data magnetotellurik 1-D merupakan data yang paling sederhana dimana pada data ini, resistivitas semu hanya bervariasi pada kedalaman. Pada data MT 1-D, model bumi dianggap sebagai model berlapis horizontal, dimana pada tiap lapisannya memiliki resistivitas homogen pada tiap lapisan (Gambar 2.6).



Gambar 2. 6 Ilustrasi model bumi berlapis horizontal (Grandis, 2009)

Pada model bumi berlapis horizontal, nilai impedansi didapatkan melalui persamaan rekursif sederhana, dimana persamaan ini menghubungkan impedansi di permukaan dua lapisan yang berurutan. Persamaan ini dinyatakan oleh:


$$Z_i = Z_{0i} \frac{1 - R_i \exp(-2k_i h_i)}{1 + R_i \exp(-2k_i h_i)} \quad (2.26)$$

Dengan:

$$R_j = \frac{Z_{0i} - Z_{i+1}}{Z_{0i} + Z_{i+1}}; Z_{0i} = \sqrt{\frac{i2\pi\mu_0\rho_i}{T}}; k_i = \frac{Z_{0i}}{\rho_i}$$

Z_i , Z_{i+1} dan Z_{0i} masing-masing merupakan impedansi pada permukaan lapisan ke- i , impedansi permukaan dibawah permukaan I, dan impedansi intrinsic lapisan ke- i dimana pada lapisan ini dianggap sebagai medium *half space* homogen. ρ_i

adalah resistivitas lapisan ke- i , T adalah periode, dan h_i adalah ketebalan lapisan ke- i . Impedansi permukaan Z_1 dapat dihitung dengan memulai perhitungan terhadap impedansi medium paling bawah dengan menggunakan Persamaan (2.13). Kemudian Persamaan (2.26) digunakan untuk menghitung impedansi untuk lapisan-lapisan yang berada diatas lapisan homogen (paling bawah). Secara sederhana, pemodelan ke depan data MT 1-D dapat dideskripsikan sebagaimana pada Gambar 2.7.



Gambar 2. 7 Prosedur pemodelan ke depan MT 1-D

BAB III METODOLOGI

3.1 Peralatan dan Bahan

Dalam penelitian ini, peralatan pendukung yang digunakan antara lain adalah MATLAB R2009a sebagai *software* utama dalam tahap pengolahan data, Satu unit PC dengan *processor* AMD sixcore 3.5GHz dan RAM 10GB, satu unit laptop dengan spesifikasi *processor* Intel Corei5 dan RAM 4GB sebagai perangkat pengolah data. Data yang digunakan adalah data rekaman magnetotellurik Alberta yang diambil pada tahun 2010.

3.2 Prosedur Kerja

Pemodelan keadaan konduktivitas bawah permukaan menggunakan data MT 1-D dengan menggunakan *Approximate Non-Dominated Sorting* (ANS) dan *Regressive-Regressive Particle Swarm Optimization* (RR-PSO). Kedua algoritma ini merupakan algoritma yang digunakan dalam optimasi minimum global. Adapun penelitian ini mengikuti alur kerja yang ditampilkan pada Gambar 3.1.

Secara garis besar, prosedur kerja yang disajikan dalam Gambar 3.1 dapat dijelaskan sebagai berikut:

1. Studi Literatur

Sebelum penelitian dilakukan, perlu adanya pemahaman mengenai konsep-konsep dan teori yang berkaitan dengan penelitian. Dilakukan proses studi literatur untuk memberikan pemahaman mengenai metode magnetotellurik dan parameter-parameter fisis yang dihasilkan, serta bagaimana proses pemodelan data magnetotellurik dilakukan dengan menggunakan algoritma *Approximate Non-Dominated Sorting* (ANS) dan *Regressive-Regressive Particle Swarm Optimization* (RR-PSO). Literatur yang dipelajari bersumber dari jurnal-jurnal internasional, tugas akhir universitas, artikel, dan buku yang berkaitan dengan magnetotellurik, optimasi multiobjektif, dan algoritma ANS dan RR-PSO.

2. Modifikasi Algoritma

Dilakukan modifikasi algoritma sebelum pengolahan data dimulai. Modifikasi dilakukan terhadap algoritma RR-PSO dengan mengganti fungsi pencarian minimum objektifnya dengan algoritma ANS yang dikembangkan oleh Zhang *et al.* (2016). Modifikasi ini dilakukan dengan tujuan agar *runtime* dari algoritma yang digunakan dapat lebih efektif dan efisien dalam pemodelan data yang akan dilakukan.

3. Algorithm Testing

Sebelum proses inversi dijalankan pada data MT 1-D, terlebih dahulu dilakukan *algorithm testing* dengan menggunakan data set Zitzler-Deb-Thiele (ZDT) 1 sampai 6 yang dikembangkan oleh Zitzler *et al.* (2000). Tahap pengujian algoritma ini dilakukan untuk melihat bagaimana performa algoritma yang digunakan terhadap suatu data. Bagus atau tidaknya solusi yang dihasilkan dapat dipantau melalui *performance indicators*. Pada penelitian ini digunakan *performance indicator* berupa *Inverted Generational Distance* (IGD).

4. Forward Modeling

Tahap *forward modeling* ini dilakukan untuk mendapatkan data sintetik berdasarkan parameter model dari model bumi berlapis yang telah ditentukan. Pada penelitian ini, digunakan empat buah model bumi berlapis. Proses *forward modeling* pada data MT 1-D dilakukan dengan menggunakan metode rekursif yang telah dibahas pada subbab 2.5 dengan parameter model berupa resistivitas dan kedalaman.

5. Pemodelan Inversi

Dalam penelitian ini proses inversi menggunakan algoritma modifikasi RR-PSO_ANS. Fungsi objektif dalam proses inversi data magnetotellurik 1D adalah resistivitas semu dan fasa dengan hasil berupa resistivitas dan ketebalan lapisan. Adapun fungsi objektif pada data magnetotellurik dinyatakan oleh:

$$S_1 = \log \left(\frac{\rho_{cal}}{\rho_{obs}} \right)^2 \quad (3.1)$$

$$S_2 = (\phi_{cal} - \phi_{obs})^2 \quad (3.2)$$

dengan S_1 adalah fungsi objektif untuk resistivitas dan S_2 adalah fungsi objektif dari fasa. Nilai misfit antara data perhitungan dan observasi dapat dihitung dengan menggunakan :

$$RMS_{1,2} = \sqrt{\frac{1}{ND}} S_{1,2} \quad (3.3)$$

dengan ND adalah banyaknya data.

Pada pemodelan inversi ini dilakukan pembangkitan 100 partikel, sehingga pada akhir pemodelan akan didapatkan 100 buah solusi. Untuk itu, perlu dilakukan penentuan solusi optimum dari semua data yang ada. Penentuan solusi optimum dilakukan menghitung jarak minimum dari fungsi objektif terhadap Pareto Minimum (D). Adapun persamaan matematis yang digunakan dalam pencarian solusi optimum adalah:


$$x(i) = \frac{x_i(j) - x_{min}}{x_{max} - x_{min}} \quad (3.4)$$

$$y(i) = \frac{y_i(j) - y_{min}}{y_{max} - y_{min}} \quad (3.5)$$

$$D = \sqrt{x^2 + y^2} \quad (3.6)$$

Dimana x dan y merupakan posisi dimana fungsi objektif resistivitas dan fasa berharga minimum. Nilai x dan y pada nilai D terkecil merujuk pada keberadaan solusi optimum dari permasalahan multiobjektif.

Pemodelan inversi yang dilakukan mengikuti diagram alir sebagai berikut:




Gambar 3. 1 Diagram Alir RR-PSO_ANG

6. Uji Variasi Iterasi

Pengujian algoritma dengan variasi iterasi dilakukan untuk melihat bagaimana RR-PSO_ANG bekerja apabila nilai iterasi yang diberikan berbeda. Digunakan nilai variasi iterasi sebanyak 50, 200, 150, dan 200.

7. Analisa Data dan Pembahasan

Setelah semua proses modeling dilakukan dan hasil didapatkan, selanjutnya dilakukan analisa data hasil forward modeling dan inversi pada tiap-tiap model bumi yang digunakan sebagai data sintetik. Begitu juga untuk data lapangan, dilakukan analisa penentuan lapisan dan estimasi ruang model pada proses inversi dan kecocokan kurva respon model lapangan dan respon model dari pemodelan inversi. Analisa data dan pembahasan selengkapnya dijabarkan pada Bab IV.



Gambar 3. 2 Diagram Alir Penelitian

“ halaman ini sengaja dikosongkan ”

BAB IV

ANALISA DATA DAN PEMBAHASAN

4.1 Pengujian Algoritma

Tahapan pengujian algoritma dilakukan untuk melihat performa dari algoritma RR-PSO_ANS untuk menyelesaikan permasalahan multiobjektif (objektif jamak). Pada penelitian ini, digunakan 5 permasalahan standar yang sering dipakai untuk menguji performa algoritma multiobjektif, yaitu: ZDT1, ZDT2, ZDT3, ZDT4, dan ZDT6 (Zitler et al., 2000). Parameter uji yang dilihat adalah waktu yang dibutuhkan suatu algoritma dalam menyelesaikan suatu permasalahan dan nilai *Inverse Generalized Distance* (IGD) yang dihasilkan. Sebagai *parameter indicator*, IGD menunjukkan bagus tidaknya solusi yang dihasilkan dengan melihat jarak euklidis dari Pareto Front (PF) dan solusi optimumnya. Semakin kecil nilai IGD menunjukkan semakin dekatnya jarak antara PF dan solusi optimumnya. Artinya, solusi aproksimasi yang dihasilkan semakin bagus

Untuk mengetahui kualitas dari algoritma RR-PSO_ANS, hasil uji yang dilakukan dibandingkan dengan hasil pengujian dari algoritma lain, dalam hal ini adalah NSGA-II. Masing-masing algoritma di proses selama 10 kali, selanjutnya masing-masing parameter yang dihasilkan dirata-ratakan. Kedua hasil pengujian algoritma yang dilakukan ditampilkan pada Tabel 4.1. Tabel 4.1 merupakan IGD dan waktu yang dibutuhkan untuk menyelesaikan parameter multiobjektif dari algoritma RR-PSO_ANS dan NSGA II. Pada keseluruhan dataset (ZDT1-ZDT4 dan ZDT6), IGD yang dihasilkan oleh NSGA-II bernilai lebih kecil dibandingkan dengan RR-PSO_ANS. Hal ini dapat disebabkan oleh cepatnya RR-PSO_ANS dalam mencapai nilai konvergensi yang begitu cepat, namun demikian, perbedaan nilai yang diberikan tidak terlalu jauh ($\pm 1 \times 10^{-5}$). Sebaliknya, terlihat perbedaan yang cukup besar pada waktu yang dibutuhkan untuk menyelesaikan permasalahan multiobjektif diantara kedua algoritma tersebut,


yakni algoritma RR-PSO_ANS 30 kali lebih cepat jika dibandingkan dengan algoritma NSGA-II.

Tabel 4. 1 Hasil Pengujian algoritma RR-PSO_ANS dan NSGA-II (tulisan tebal menunjukkan hasil yang terbaik)

Data Model	RR-PSO_ANS		NSGA II	
	Waktu (s)	IGD	Waktu (s)	IGD
ZDT1	16.028	9.14×10^{-5}	595.439	8.494×10^{-5}
ZDT2	15.9804	8.72×10^{-5}	590.961	8.494×10^{-5}
ZDT3	14.35	4.22×10^{-3}	585.280	8.828×10^{-5}
ZDT4	39.23	9.088×10^{-5}	575.873	8.987×10^{-5}
ZDT6	13.474	9.811×10^{-5}	556.634	9.797×10^{-5}

Distribusi PF hasil aproksimasi kedua algoritma disajikan pada Gambar 4.1. Terlihat pada kedua gambar bahwa distribusi PF hasil estimasi sangat mendekati nilai *Pareto Front* (PF) yang sebenarnya baik pada RR-PSO_ANS dan NSGA-II. Begitu juga dengan pola distribusi PF aproksimasi RR-PSO_ANS dengan NSGA-II, yang mana keduanya terlihat sama, kecuali pada ZDT6.


Pada data ZDT6, terdapat beberapa PF yang berada sedikit jauh dari PF pada data hasil estimasi RR-PSO_ANS. Hal tersebut dapat disebabkan oleh cepatnya konvergensi sehingga algoritma kesulitan untuk mencari PF yang tepat. Hal ini dapat menyebabkan RR-PSO memiliki resiko terjebak pada minimum lokal.



Gambar 4. 1 Kurva IGD terhadap Iterasi

Kecepatan konvergensi IGD menuju ke nilai nol dari RR-PSO_ANS dapat dilihat pada Gambar 4.1 yang menunjukkan kurva konvergensi IGD dari NSGA-II dan RR-PSO_ANS. Pada data ZDT6, RR-PSO_ANS hanya membutuhkan 2 kali iterasi untuk menuju ke nilai nol, sedangkan pada data NSGA-II, konvergensi baru terjadi pada iterasi ke 30. Hal ini menimbulkan kemungkinan bahwa solusi dari RR-PSO_ANS dapat terjebak pada nilai minimum lokal. Meskipun demikian, kemungkinan RR-PSO_ANS untuk terjebak pada minimum lokal sangat kecil, hal ini karena terdapat proses mutasi, dimana pada proses ini dihasilkan partikel-partikel baru yang bertujuan untuk mengeksplor area pencarian lebih banyak lagi dan mengurangi kemungkinan RR-PSO_ANS untuk mengalami konvergensi yang terlalu cepat, sehingga kemungkinan terjebak di minimum lokal dapat diantisipasi. Selain itu, mutasi ini juga berfungsi untuk meningkatkan persebaran solusi non-dominasi pada suatu Front

dengan memperkecil nilai IGD dan mengisi ruang kosong (*gap*) pada Front solusi non-dominasi.



Gambar 4. 2 Distribusi Pareto Front terhadap *True Pareto* (hitam) dari hasil aproksimasi menggunakan RR-PSO_ANS (merah) dan NSGA-II (biru) pada data set ZDT dengan 10 kali proses

Dari data hasil pengujian algoritma yang dilakukan, yangmana hasil perolehan dari RR-PSO_ANS dan NSGA-II menghasilkan kurva yang hampir sama, didapatkan bahwa algoritma RR-PSO_ANS memiliki tingkat keefisienan pencarian solusi yang lebih baik dari pada NSGA-II. RR-PSO_ANS menghasilkan nilai IGD dengan selisih yang sangat kecil dengan NSGA-II dan waktu yang digunakan dalam pencarian solusi setidaknya 30 kali lebih cepat daripada NSGA-II. Selain itu, kedua PF yang dihasilkan algoritma RR-PSO_ANS dan NSGA-II sangat dekat dengan PF yang sebenarnya.

4.2 Pemodelan Ke Depan


Untuk mengetahui bagaimana performa dari RR-PSO_ANS dalam menyelesaikan permasalahan bumi berlapis, maka dibuat suatu model lapisan sintetik. Empat model lapisan bumi yang digunakan dalam pembuatan data sintetik disajikan pada Tabel 4.2.

Tabel 4.2. Model lapisan yang digunakan dalam pembuatan data sintetik


Jumlah Lapisan	Model Lapisan	Ketebalan (m)	Resistivitas (Ωm)
3 Lapisan	Resistif diantara Konduktif	500	50 1200 500
	Konduktif diantara Resistif	1000	500 50 1200
5 Lapisan	Konduktif	600 1300 3500 4000	300
	Resistif		2500
	Konduktif		50
	Resistif		3000
5 Lapisan	Konduktif	3500 4000	2000
	Resistivitas		400
	Meningkat		600
	terhadap		800
	Kedalaman		1000 2500

Pemodelan kedepan dilakukan pada keempat model perlapisan (Tabel 4.2) dengan menggunakan persamaan rekursif (Persamaan 2.26). Pada data MT 1D, medium bumi dianggap sebagai homogen isotropis. Artinya, parameter fisis hanya akan berubah pada lapisan yang berbeda.

Tahap pemodelan pertama dilakukan terhadap model bumi 3 lapisan dengan lapisan terakhir merupakan lapisan *half space*, yaitu lapisan dengan ketebalan tak hingga. Frekuensi yang digunakan dalam pemodelan ini berkisar antara 10^{-3} sampai dengan 10^3 Hz. Pada akhir proses pemodelan akan didapatkan data parameter fisis berupa resistivitas semu (ρ_a), dan fasa (ϕ). Kurva pemodelan ρ_a dan ϕ ditunjukkan oleh Gambar 4.3 dan 4.4. Kedua gambar tersebut merepresentasikan kondisi tiap-tiap bagian dari model perlapisan. Gambar 4.3 (a) dan 4.4 (a) menunjukkan kurva resistivitas semu didapatkan setelah melakukan perhitungan dengan Persamaan Rekursif.



Gambar 4. 3 Data MT sintetis 3 lapisan resistif diantara konduktif, (a) Resistivitas semu, (b) Fasa, (c) Resistivitas bawah permukaan.



Gambar 4. 4 Data MT sintetis 3 konduktif diantara resistif, (a) Resistivitas semu, (b) Fasa, (c) Resistivitas bawah permukaan.


Mengikuti asumsi-asumsi studi magnetotellurik 1D yang dijelaskan oleh Simpson dan Bahr (2005) pada Bab 2, yang membahas bahwa resistivitas pada suatu lapisan bumi dianggap seragam dan hanya akan bernilai berbeda pada lapisan yang berbeda. Lapisan konduktif pada kurva resistivitas sebagai fungsi periode ditunjukkan pada bagian lembah yang memiliki nilai resistivitas semu yang rendah. Sebaliknya, pada lapisan resistif, kurva akan berada pada nilai yang tinggi. Pada model bumi homogen berlapis seperti yang digunakan pada penelitian ini, kurva akan memiliki bentuk seperti lembah dan bukit yang menunjukkan adanya lebih dari satu lapisan akibat adanya perbedaan nilai resistivitas, dimana bagian lembah menunjukkan lapisan yang konduktif, dan bagian bukit akan menunjukkan lapisan resistif.

Kurva fasa pada Gambar 4.3(b) dan 4.4(b) juga dapat digunakan untuk melihat ada berapa lapisan yang diteliti. Perubahan bentuk kurva dari lembah menjadi bukit dan sebaliknya menunjukkan adanya perubahan medium yang dilewati oleh medan elektromagnetik.

Gambar 4.3(c) dan 4.4(c) menunjukkan gambaran kondisi bawah permukaan dari model bumi yang digunakan. Tampak


bahwa resistivitas bervariasi terhadap kedalaman. Resistivitas pada tiap lapisan merupakan representasi dari sifat-sifat batuan-batuan atau material lain yang menyusun lapisan tersebut.

Berikutnya adalah pemodelan kedepan pada model bumi 5 lapisan. Adanya variasi perlapisan yang lebih banyak ditujukan untuk mengetahui bagaimana algoritma menyelesaikan permasalahan dengan parameter model yang lebih banyak. Ada dua jenis model yang digunakan pada variasi 5 lapisan ini yaitu model resistif diantara konduktif dan model yang resistivitasnya meningkat sesuai dengan kedalaman. Hasil pemodelan kedepan dari model 5 lapisan disajikan pada Gambar 4.5 dan 4.6.



Gambar 4. 5 Hasil pemodelan kedepan pada model 5 lapisan konduktif-resistif-konduktif-resistif-konduktif. (a) Resistivitas Semu dan (b) Fasa. Gambar (c) merupakan gambaran distribusi resistivitas bawah permukaan.

Seperti yang telah dijelaskan sebelumnya, pada kurva resistivitas semu, lapisan konduktif ditunjukkan oleh bagian lembah kurva dan lapisan resistif ditunjukkan oleh bagian bukit kurva, dan kurva fasa digunakan untuk pertimbangan berapa jumlah lapisan yang dilewati oleh gelombang elektromagnet.




Gambar 4. 6 Hasil pemodelan kedepan pada model 5 lapisan dengan resistivitas yang meningkat dengan kedalaman. (a) Resistivitas Semu dan (b) Fasa. Gambar (c) merupakan gambaran distribusi resistivitas bawah permukaan.

4.3 Inversi Data Sintetik

Setelah didapatkan resistivitas semu dan fasa melalui pemodelan kedepan yang selanjutnya disebut sebagai data observasi, diinversi dengan menggunakan algoritma RR-PSO_ANS untuk mengestimasi ketebalan dan resistivitas pada tiap lapisan. Pada keempat data model diinversi menggunakan algoritma RR-PSO_ANS dengan membangkitkan 100 populasi dengan iterasi sebanyak 500. Penentuan kecepatan partikel dilakukan sesuai dengan Persamaan (2.23) dengan rentang acak *uniform*. Selain itu, untuk mengontrol agar pencarian solusi tetap seimbang dan tidak terlalu jauh saat kecepatan menjadi semakin tinggi, diberikan suatu faktor inersia sebagai pengontrol. Faktor inersia yang biasa digunakan berada diantara 0,8 sampai 1,2. Pada penelitian ini, digunakan faktor inersia sebesar 0,8, dan faktor percepatan partikel c_1 dan c_2 sebesar 0,05. Eberhart and Shi (2005) mengungkapkan bahwa nilai c yang kecil akan menyebabkan partikel dapat bergerak menjelajahi ruang model pada jarak yang jauh dari area target sebelum akhirnya kembali. Nilai c yang besar akan menyebabkan pergerakan partikel yang


tiba-tiba menuju area target tanpa melakukan penjelajahan area yang lain. Hasil inversi ke empat data model dapat dilihat pada Gambar 4.7–4.10. dengan indeks (a) merupakan resistivitas semu sebagai fungsi periode, (b) fasa sebagai fungsi periode, (c) nilai RMS dari resistivitas semu (sumbu x) dan fasa (sumbu y), dan (d) adalah gambaran perlapisan bawah permukaan dari masing-masing model.



Gambar 4. 7 Hasil inversi dengan algoritma RR-PSO_ANS pada model 3 lapisan resistif diantara konduktif.

Gambar 4.7 menunjukkan bahwa nilai resistivitas semu dan fasa hasil inversi mirip atau berhimpit dengan data observasi. Hal ini didukung dengan nilai dari fungsi *misfit* atau RMS yang dihasilkan yang menunjukkan informasi mengenai kemiripan data hasil inversi dengan model awal. Nilai RMS yang dihasilkansangat kecil, yaitu hanya sekitar 10^{-1} - 10^{-3} untuk kedua respon model (resistivitas semu dan fasa). Artinya, model bawah permukaan hasil inversi yang dihasilkan sangat mendekati data sebenarnya. Hal yang sama juga terjadi pada model 3 lapisan konduktif diantara resistif, dan kedua model 5 lapisan. Kecilnya nilai RMS pada fasa menunjukkan bahwa pengaruh fasa yang diberikan fasa dalam pengukuran tidak sebesar pengaruh yang diberikan oleh resistivitas lapisan. Oleh karena itu, pada MT 1D,


kurva fasa biasanya digunakan sebagai data pendukung dalam penentuan perlapisan.




Gambar 4. 8 Hasil inversi dengan algoritma RR-PSO_ANS pada model 3 lapisan resistif diantara konduktif.

Model bawah permukaan Gambar 4.8 (d) lebih baik dari pada Gambar 4.7(d). Pada model 3 lapisan konduktif diantara resistif (Gambar 4.7(d)), *best solution* yang didapatkan tidak sebagus Gambar 4.8. Meskipun data observasi dan data inversi, pada lapisan kedua tampak *best solution* dari kurva resistivitas semu (garis putus-putus merah) yang agak menyimpang dari model awal. Disamping itu, *best solution* dari nilai RMS keduanya (bulatan merah jambu) juga menunjukkan bahwa nilai RMS model kedua lebih kecil daripada model pertama. Data RMS untuk masing-masing lapisan dapat dilihat pada Tabel 4.3.

Gambar 4.9 dan 4.10 merupakan hasil inversi dari model 5 lapisan. Solusi optimum yang didapatkan memiliki kualitas yang sangat bagus dimana sama seperti kedua model sebelumnya, kurva resistivitas semu dan fasa terlihat berhimpit antara data observasi dan model inversi.



Gambar 4. 9 Hasil inversi dengan algoritma RR-PSO_ANS pada model 5 lapisan konduktif- resistif-konduktif-resistif-konduktif.



Gambar 4. 10 Hasil inversi dengan algoritma RR-PSO_ANS pada model 5 lapisan resistif diantara konduktif.

Hal ini menunjukkan bahwa, meskipun terjadi penambahan jumlah parameter model, RR-PSO_ANS masih dapat bekerja dengan baik. Terdapat beberapa hal yang bisa memengaruhi hasil pemodelan inversi yang dilakukan. Pertama, bertambahnya parameter model sehingga beban kerja dari algoritma bertambah untuk menemukan solusi yang optimum. Kedua, karakteristik dari metode MT secara khusus dan metode geofisika pada umumnya, yakni ketidakpastian solusi model dari metode geofisika berbanding lurus dengan kedalaman. Faktor lain yang berpengaruh dalam penentuan solusi akhir dari inversi adalah pemberian kecepatan partikel untuk mencapai titik konvergensi. Proses konvergensi yang terlalu cepat menyebabkan hasil inversi dapat terjebak pada minimum lokal, sehingga perlu diberikan suatu faktor inersia untuk mengimbangnya. Selain itu, lebar ruang model juga memengaruhi solusi dari pemodelan inversi. Ruang model adalah ruang model tempat partikel-partikel bergerak untuk mencari solusi optimum. Ruang model bisa ditentukan melalui besaran *skindepth*. Namun, yang menjadi acuan utama dalam penentuan ruang model adalah nilai maksimum dan minimum dari model awal yang diberikan. Penentuan ruang model tidak boleh terlalu lebar untuk menghindari banyaknya nilai optimum lokal yang dihasilkan, dan tidak boleh pula terlalu sempit mengingat faktor reduksi yang ada pada pemodelan. Ruang model yang tepat akan menghasilkan hasil inversi yang optimum dengan nilai RMS yang kecil. Tabel 4.3 merupakan nilai RMS hasil inversi untuk keempat model sintetik. Nilai RMS yang dihasilkan menyatakan besarnya nilai *misfit* antara data observasi dan data inversi. Artinya, semakin kecil nilai RMS yang dihasilkan, maka kecocokan nilai antara data observasi dan data inversi juga semakin dekat.

Tabel 4. 3 Data nilai RMS hasil inversi dari keempat model perlapisan

Jumlah Lapisan	Model Lapisan	RMS Resistivitas Semu	RMS Fasa
3 Lapisan	Resistif	0.0012	0.0072

	diantara Konduktif		
	Konduktif diantara Resistif	0.0020	0.0266
5 Lapisan	Konduktif Resistif Konduktif Resistif Konduktif	0.0079	0.0345
	Resistif seiring dengan Kedalaman	0.0023	0.0146

Hasil inversi RR-PSO_ANS pada penelitian ini tidaklah tunggal. RR-PSO_ANS menghasilkan satu set model solusi yang disebut dengan Pareto Optimum (PO), dimana pada penelitian ini terdapat 100 buah model dalam PO yang dihasilkan. Seluruh model dalam PO ini memiliki nilai yang hampir mirip antara satu sama lain, dan semuanya dapat dijadikan solusi dari permasalahan inversi yang diselesaikan. Namun, pada penelitian ini hanya dipilih satu solusi terbaik, dimana solusi ini memiliki nilai jarak minimum (Persamaan 3.5) yang paling kecil dan nilai yang paling mendekati dengan nilai model sebenarnya, dimana data terbaik ini memiliki nilai RMS yang paling kecil dibandingkan dengan model lainnya.

Tabel 4.4 berikut ini merupakan data *best solution* keempat model sintetik yang didapatkan dari hasil inversi. Tampak bahwa semua solusi sangat mendekati model awal yang diberikan dengan perbedaan yang kecil.

Tabel 4. 4 *Best solution* hasil inversi keempat model sintetik

Model Lapisan	<i>True Model</i>	Model Inversi (Solusi Optimum)
------------------	-------------------	-----------------------------------


	Ketebalan (m)	Resistivitas (Ωm)	Ketebalan (m)	Resistivitas (Ωm)
Resistif diantara Konduktif	500 1000	500	498.621	498.99
		50	1007.21	50.23
		1200	Halfspace	1199.08
Konduktif diantara Resistif		50	499.27	49.96
1200		993.59	1186.34	
500		Halfspace	499.30	
Konduktif Resistif Konduktif Resistif Konduktif	600 1300 3500 4000	300	599.88	300.83
2500		1306.98	2480.07	
50		3505.23	50.39	
3000		4036.08	2991.61	
2000		Halfspace	2018.41	
Resistif seiring dengan Kedalaman		400	595.20	399.48
		600	1305.38	596.59
		800	3506.21	801.04
		1000	3953.30	994.73
		2500	Halfspace	2490.18

Keempat data sintetis yang digunakan telah diinversi dan menghasilkan solusi yang mendekati dengan model awal. Ramadhani (2016) melakukan penelitiannya dengan menggunakan algoritma NSGA-II, yangmana seperti yang telah dipaparkan pada subbab 4.1, algoritma ini memiliki nilai IGD yang lebih kecil dibandingkan dengan RR-PSO_ANS, artinya, pendekatan terhadap solusi optimum dari NSGA-II umumnya akan lebih bagus dibandingkan dengan RR-PSO_ANS, walau tidak berbeda jauh. Selain itu, NSGA-II juga memiliki ketelitian yang lebih baik dalam menentukan Meskipun begitu, inversi data lapangan RR-PSO_ANS menunjukkan yang sedikit lebih unggul dibandingkan dengan inversi yang dilakukan oleh Ramadhani (2016), diantaranya adalah waktu eksekusi yang lebih cepat

dengan jumlah iterasi lebih banyak pada jumlah lapisan yang sama. Dengan demikian, kinerja dari algoritma RR-PSO_ANS telah terbukti bekerja dengan sangat baik dalam menyelesaikan permasalahan multiobjektif dengan lebih dari satu parameter model.

4.4 Analisa Data Lapangan

Setelah berhasil dalam menginversi data sintetik, selanjutnya algoritma RR-PSO_ANS diimplementasikan pada sebuah data lapangan. Data lapangan yang digunakan bersumber dari Alberta yang diambil pada tahun 2010. Sebagaimana yang telah dibahas sebelumnya, penentuan ruang model merupakan faktor penting dalam proses inversi yang dilakukan. Sama halnya dengan data sintetik, penentuan ruang model dilakukan dengan memperhatikan kurva respon model dari data lapangan untuk mengestimasi jumlah lapisan pengukuran. Gambar 4.11 merupakan kurva respon model dari data lapangan yang digunakan. Kurva *skindepth* pada Gambar 4.11 (c) menggambarkan kedalaman penetrasi perekaman data. Selain resistivitas dan fasa, parameter ini juga sangat berguna dalam melakukan penentuan ruang model untuk proses inversi.



Gambar 4.11 Profil bawah permukaan data lapangan. (a) Resistivitas semu, (b) fasa, (c) *skindepth*


Tabel 4. 5 Estimasi ruang model pada data lapangan

Model Lapisan	Lapisan ke-	Ketebalan (m)		Resistivitas (Ωm)	
		Min	Max	Min	Max
Konduktif	1	10	150	0,05	10
Resistif	2	50	1000	10	50
Konduktif	3	100	10000	10	250
Resistif	4	4000	168000	50	300
Konduktif	5	Halfspace		50	250

Berbeda dengan data sintetik pada subbab sebelumnya, data lapangan hanya memiliki respon berupa resistivitas semu dan fasa saja, sehingga perlu dihitung nilai *skindepth* berdasarkan Persamaan (2.12) untuk mengestimasi ketebalan lapisan dari data lapangan. Berdasarkan Gambar 4.11c, diperkirakan terdapat lima lapisan pada data yang digunakan, dengan model lapisan berupa

lapisan resistif diantara konduktif, dan estimasi ruang model yang digunakan untuk data ini disajikan pada Tabel 4.5.

Gambar 4.12 merupakan hasil inversi data lapangan dengan RR-PSO_ANS menggunakan ruang model yang terdapat pada Tabel 4.5. Kurva resistivitas semu dan fasa yang terdapat pada Gambar 4.12 tampak berhimpit pada beberapa bagian, hal tersebut menunjukkan bahwa pemilihan ruang model pada proses inversi yang dilakukan sudah tepat. Selain itu, solusi model yang dihasilkan juga berada pada interval standar deviasi data lapangan yang menunjukkan bahwa solusi dari pendekatan yang dilakukan masih berada daerah kemungkinan distribusi nilai solusi. Solusi model bawah permukaan pada Gambar 4.12(c) menunjukkan ketidakpastian yang cukup besar (garis kurva abu-abu) seiring dengan meningkatnya kedalaman. Besar kecilnya nilai ketidakpastian dari data pengukuran tersebut dapat dipengaruhi oleh beberapa faktor, diantaranya adalah *noise* yang diterima saat pengukuran, serta kurangnya data *constraint* dalam menentukan solusi, serta pengaruh sifat fisis dari parameter yang diukur.



Gambar 4. 12 Hasil Inversi RR-PSO_ANS terhadap data lapangan

Gambar 4.12 (a) menunjukkan bahwa data hasil inversi mendekati data pengukuran untuk resistivitas, sedangkan untuk kurva fasa pada Gambar 4.12 (b) masih memperlihatkan beberapa data yang kurang dekat dengan data lapangan. Hal ini dapat disebabkan karena tidak adanya faktor pembobot yang diberikan pada saat inversi sehingga kurva fasa menunjukkan nilai kecocokan yang kurang baik. Tidak adanya faktor pembobot pada inversi RR-PSO_ANS menyebabkan tidak adanya faktor yang dapat mengurangi nilai *misfit* pada data kurva fasa. Dipaparkan oleh Grandis (2001) bahwa terkadang kualitas data fasa yang terukur tidak terlalu bagus atau bahkan tidak bisa digunakan sama sekali, karena itu kura fasa hanya dijadikan sebagai data pendukung dalam penentuan perlapisan. Hasil terbaik dari proses inversi data lapangan disajikan pada Tabel 4.6.

Tabel 4. 6 Hasil terbaik implementasi inversi RR-PSO_ANS pada data lapangan

Model Lapisan	<i>Best Solution</i>		<i>RMS Best Solution</i>	
	Ketebalan (m)	Resistivitas (Ωm)	Resistivitas	Fasa
Resistif diantara Konduktif	33.580	6.87	0.152	4.088
	996.800	12.702		
	1435.317	57.261		
	105927.480	298.835		
	<i>Halfspace</i>	55.426		

Hasil inversi data magnetotellurik 1D dengan menggunakan *MOEA* pada penelitian yang dilakukan Ramadhani (2016) dan Pramudiana (2016) menunjukkan bahwa algoritma yang digunakan pada masing-masing penelitian mampu mengestimasi parameter fisis berupa resistivitas dan ketebalan lapisan. Membandingkan dengan penelitian-penelitian tersebut, inversi menggunakan RR-PSO_ANS pada penelitian ini menghasilkan kualitas kecocokan kurva yang hampir sama,


bahkan pada beberapa titik, RR-PSO_ANS memiliki nilai kecocokan kurva yang lebih bagus dibandingkan dengan keduanya.

Berdasarkan hasil inversi data lapangan ini, dapat diketahui bahwa RR-PSO_ANS mampu digunakan dalam penentuan parameter fisis pada data magnetotellurik 1D dengan kecepatan pencarian solusi optimum dan cepat serta hasil respon model dari inversi yang mendekati model yang sebenarnya.

4.5 Uji Variasi Iterasi


Penambahan ANS yang dilakukan pada algoritma RR-PSO ditujukan untuk mempercepat proses komputasi dalam pencarian solusi optimum. Dengan sifat pencapaian konvergensi yang bagus dari RR-PSO dan kecepatan komputasi yang diberikan oleh ANS membuat RR-PSO_ANS menjadi pengembangan MOEA dengan kualitas performa yang unggul dalam penentuan solusi optimum pada permasalahan optimasi multiobjektif.

Salah satu parameter yang berpengaruh pada performa MOEA adalah iterasi. Semakin banyak iterasi yang digunakan dalam suatu optimasi, maka akan semakin dekat solusi yang dihasilkan dengan data sebenarnya. Untuk mengetahui bagaimana pengaruh iterasi pada performa RR-PSO_ANS, maka dilakukan proses inversi pada salah satu data sintetis, yaitu pada data lima lapisan resistif diantara konduktif dengan iterasi yang berbeda. Variasi iterasi yang diberikan adalah 50,100,150, dan 200.



Gambar 4. 13 Hasil inversi data sintetis dengan menggunakan 50 iterasi


Pada Gambar 4.13 ditunjukkan hasil inversi pada data sintetis lima lapisan model resistif diantara konduktif dengan iterasi sebanyak 50. Jika dibandingkan dengan hasil proses inversi data sebelumnya yang memiliki 500 iterasi (Gambar 4.9), hasil dari inversi ini ternyata juga menunjukkan kecocokan kurva yang bagus. Selain itu, hasil inversi juga menunjukkan solusi model dan solusi optimum yang mendekati model sebenarnya (Gambar 4.14)



Gambar 4. 14 Model hasil inversi RR-PSO_ANS dengan 50 iterasi.


Hal ini menunjukkan bahwa meskipun iterasi pada proses inversi yang dilakukan tidak banyak, namun RR-PSO_ANS sudah mampu dalam menentukan solusi optimum dari permasalahan multiobjektif. Seperti yang telah dibahas pada subbab 4.1, RR-PSO memiliki tingkat konvergensi yang sangat cepat, hanya pada beberapa iterasi saja, algoritma ini sudah mampu mencapai nilai nol, sehingga tidak diperlukan terlalu banyak iterasi pada pemodelan ini untuk bisa menemukan solusi optimum bagi suatu permasalahan multiobjektif. Keadaan yang sama juga terjadi pada inversi dengan iterasi 100, 150, dan 200 yang disajikan pada Lampiran A.

Selain itu, pengaruh iterasi pada pemodelan inversi yang dilakukan berada pada distribusi PF dari RR-PSO_ANS. Pada pemodelan inversi dengan jumlah iterasi sebanyak 50, distribusi PF tampak tidak beraturan dan berjarak sedikit lebih jauh dibandingkan dengan data inversi dengan iterasi 500. Persebaran PF untuk data dengan 50 iterasi dapat dilihat pada gambar 4.15.



Gambar 4. 15 Distribusi PF pada data 5 lapisan dengan 50 iterasi.

Sedangkan pada data dengan iterasi yang lebih besar, jarak antar PF akan semakin berdekatan dan konvergensinya akan semakin tinggi. Gambar 4.16 menunjukkan distribusi PF dengan iterasi sebanyak 150. Dibandingkan dengan persebaran PF pada 50 iterasi, PF pada 150 iterasi menunjukkan posisi yang lebih berdekatan dan mendekati nilai nol.



Gambar 4. 16 Distribusi PF pada data 5 lapisan dengan 150 iterasi.

Dan dengan variasi iterasi yang diberikan, didapatkan bahwa semakin banyak iterasi yang digunakan, maka jarak antar PF akan menjadi lebih dekat dan nilai PF akan semakin tereduksi. Semakin kecilnya nilai PF bersamaan dengan semakin banyaknya iterasi diharapkan dapat menghasilkan solusi non dominasi yang lebih baik, oleh karena itu, pada digunakan iterasi sebanyak 500 sebagai upaya untuk mendapatkan solusi optimum yang lebih baik pula.

BAB V

KESIMPULAN DAN SARAN

a. Kesimpulan

Berdasarkan dari hasil inversi menggunakan algoritma RR-PSO_ANS yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut :

1. Meskipun memiliki nilai IGD yang lebih besar daripada NSGA-II, RR-PSO_ANS memiliki waktu komputasi 30 kali lebih cepat dan model *Pareto Front* yang dihasilkan juga mendekati nilai dari *True Pareto Front*.
2. Solusi dari pemodelan inversi data sintetik dan lapangan menunjukkan hasil yang sangat mendekati dengan model awal yang diberikan.
3. RR-PSO_ANS mampu menyelesaikan permasalahan multiobjektif dengan cepat meskipun terjadi penambahan parameter model. Selain itu, RR-PSO_ANS juga mampu untuk mengestimasi parameter resistivitas dan ketebalan dari perlapisan bumi pada data suatu pengukuran dengan sangat baik.
4. RR-PSO_ANS dapat diterapkan pada permasalahan optimasi data magnetotellurik 1D.

b. Saran

Setelah dilakukannya penelitian ini maka diperoleh beberapa hal yang dapat disarankan untuk menjadi bahan perbandingan dalam penelitian yang akan lebih lanjut, di antara lain sebagai berikut:

1. Mengaplikasikan algoritma RR-PSO_ANS untuk joint inversi data geofisika
2. Mengaplikasikan algoritma RR-PSO_ANS pada data magnetotellurik 2D

“halaman ini sengaja dikosongkan ”

DAFTAR PUSTAKA

- Campbell, W.H., 1987. Electrical Properties of the Earth's Mantle. Birkhäuser Basel, Basel.
- Connolly, J.A.D., Khan, A., 2016. Uncertainty of mantle geophysical properties computed from phase equilibrium models: PHASE EQUILIBRIUM UNCERTAINTY. *Geophysical Research Letters* 43, 5026–5034. doi:10.1002/2016GL068239
- Dal Moro, G., 2011. Some aspects about surface wave and HVSr analyses: A short overview and a case study. *Bollettino Geofisica Teorica ed Applicata* 52, 241–259.
- Eberhart, R.C., Kennedy, J., others, 1995. A new optimizer using particle swarm theory, in: *Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. New York, NY, pp. 39–43.
- Fernández Martínez, J.L., Fernández Muñiz, M.Z., Tompkins, M.J., 2012. On the topography of the cost functional in linear and nonlinear inverse problems. *GEOPHYSICS* 77, W1–W15. doi:10.1190/geo2011-0341.1
- Fomel, S., Landa, E., 2014. Structural uncertainty of time-migrated seismic images. *Journal of Applied Geophysics* 101, 27–30. doi:10.1016/j.jappgeo.2013.11.010
- Giancarlo, D.M., 2010. Insights on surface wave dispersion and HVSr: Joint analysis via Pareto optimality. *Journal of Applied Geophysics* 72, 129–140. doi:10.1016/j.jappgeo.2010.08.004
- Grandis, H. 2009. *Pengantar Pemodelan Inversi Geofisika*. HAGI: Jakarta
- Grandis, H., n.d. *Aplikasi Metode Simulated Annealing pada Inversi Data Magnetotellurik 1-D* (Hendra Grandis1, 3), (Priyadi SA 2), (Tita R. Puspita3).

- Hakim, Agung Mahesya, Dkk. 2014. Modul Eksplorasi Elektromagnetik. Bandar Lampung: Teknik Geofisika 2011 Universitas Lampung
- Kan, A.R., Boender, C.G.E., Timmer, G.T., 1985. A stochastic approach to global optimization, in: Computational Mathematical Programming. Springer, pp. 281–308.
- Laby, D.A., Sungkono, Santosa, B.J., Bahri, A.S., 2016. RR-PSO: fast and robust algorithm to invert Rayleigh waves dispersion. Contemporary Engineering Sciences 9, 735–741. doi:10.12988/ces.2016.6685
- Li, M., Du, W., Nian, F., 2014. An Adaptive Particle Swarm Optimization Algorithm Based on Directed Weighted Complex Network. Mathematical Problems in Engineering 2014, 1–7. doi:10.1155/2014/434972
- Martínez, J.F., Gonzalo, E.G., TWO ALGORITHMS OF THE EXTENDED PSO FAMILY:, 2010.. SciTePress - Science and and Technology Publications, pp. 237–242. doi:10.5220/0003085702370242
- Martínez, J.F., Gonzalo, E.G., Muñiz, Z.F., Mariethoz, G., Mukerji, T., 2012. Posterior sampling using particle swarm optimizers and model reduction techniques. Principal Concepts in Applied Evolutionary Computation: Emerging Trends: Emerging Trends 192.
- Mashwani, W.K., Salhi, A., Khanum, R.A., Sulaiman, M., n.d. Enhanced Version of Multi-algorithm Genetically Adaptive for Multiobjective optimization.
- Menke, W., 1984. Geophysical data analysis: discrete inverse theory. Academic Press, Orlando, Fla.
- N. Dwi, Wahyu, et.al. 2013. Modul 4: Metode Magnteotellurik Institut Teknologi Bandung.
- Rini, D.P., Shamsuddin, S.M., Yuhaniz, S.S., 2011. Particle swarm optimization: technique, system and challenges. International Journal of Computer Applications 14, 19–26.

- Rokityansky I.I. 1982. Geoelectromagnetic Investigation of the Earth's Crust and Mantle. Springer Verlag Berlin Heidelberg.
- Seshadri, A., 2006. Multi-objective optimization using evolutionary algorithms (MOEA). Matlab Website: <http://www.mathworks.com/matlabcentral/fileexchange/10429>, by 19.
- Shi, Y., others, 2001. Particle swarm optimization: developments, applications and resources, in: Evolutionary Computation, 2001. Proceedings of the 2001 Congress on. IEEE, pp. 81–86.
- Simpson, F., Bahr, K., 2005. Practical Magnetotellurics. Cambridge University Press, Cambridge, UK ; New York.
- Spall, J.C., 2012. Stochastic optimization, in: Handbook of Computational Statistics. Springer, pp. 173–201.
- Supriyanto, E., Fisika-FMIPA, D., 2007. Analisis Data Geofisika: Memahami Teori Inversi. Depok: Universitas Indonesia.
- Talbi, E.-G., 2009. Metaheuristics: from design to implementation. John Wiley and Sons, Hoboken, N.J.
- Tarantola, A., 2005. Inverse problem theory and methods for model parameter estimation. Society for Industrial and Applied Mathematics, Philadelphia, PA.
- Zhang, X., Tian, Y., Jin, Y., 2016. Approximate Non-Dominated Sorting For Evolutionary Many-Objective Optimization. Information Sciences 369, 14–33. doi:10.1016/j.ins.2016.06.007
- Zitzler, E., Deb, K., Thiele, L., 2000. Comparison of multiobjective evolutionary algorithms: Empirical results. Evolutionary computation 8, 173–195.


“ halaman ini sengaja dikosongkan ”

LAMPIRAN A


Hasil Inversi RR-PSO_ANS dengan Variasi Iterasi

1. 50 iterasi


a. Kecocokan Kurva




b. Distribusi Pareto Front



2. 100 iterasi
a. Kecocokan Kurva




b. Distribusi Pareto Front




3. 150 iterasi

a. Kecocokan Kurva




b. Distribusi Pareto Front




4. 200 iterasi

a. Kecocokan Kurva



b. Distribusi Pareto Front



BIOGRAFI PENULIS



Penulis “Haiyina Hasbia Amania” merupakan anak ke 3 dari 4 bersaudara yang dilahirkan di Kota Surabaya pada 1 April 1994. Penulis menempuh pendidikan formal antara lain di TK Muslimat NU 08 Banjarjo, SDN Sukolilo 606 Bancar Tuban, MTs. YKUI Maskumambang Gresik, dan SMAN 1 Tuban. Penulis menjadi mahasiswi Fisika ITS sejak tahun 2012 melalui jalur masuk SNMPTN tulis dan terdaftar dengan NRP 111210091. Selama menjadi mahasiswi Fisika ITS, penulis aktif di beberapa organisasi seperti HIMASIKA ITS selama 2 kepengurusan, SEG ITS SC, dan SPE ITS SC selama 1 kepengurusan. Harapan penulis adalah agar karya ini dapat bermanfaat untuk pembacanya sebagai sarana mengemabangkan potensi diri untuk melakukan penelitian-penelitian terkait. Kritik dan saran yang bersifat membangun dapat dikirim ke haiyinahasbi@gmail.com.